

Hybride Fehlerprognose zur Unterstützung prädiktiver Instandhaltungskonzepte in der Luftfahrt

Vom Fachbereich Maschinenbau
an der Technischen Universität Darmstadt

zur

Erlangung des Grades eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte

DISSERTATION

vorgelegt von

Dipl.-Ing. Heiko Mikat

aus Berlin/Deutschland

Berichterstatter:

Prof. Dr.- Ing. Uwe Klingauf

Mitberichterstatter:

Prof. Dr.- Ing. Eberhard Abele

Tag der Einreichung:

27.11.2014

Tag der mündlichen Prüfung:

24.02.2015

Darmstadt 2015

D17

„Wenn wir die Differenz von gegenwärtiger Zukunft und künftigen Gegenwarten durch Annahmen über Wahrscheinlichkeiten und Unwahrscheinlichkeiten überbrücken, heißt dies, dass über Zukunft nur im Modus der Unsicherheit gesprochen werden kann.“

Niklas Luhmann

Inhalt

Nomenklatur.....	VIII
Abstract.....	XII
Zusammenfassung	XIII
1. Einleitung	1
1.1. Motivation	1
1.1.1. Kosteneffizienz	3
1.1.2. Operationelle Leistungsfähigkeit	5
1.1.3. Zusammenfassung.....	7
1.2. Zielsetzung und Vorgehensweise	8
1.2.1. Modellbasierte Potentialanalyse von Zustandsüberwachungssystemen	8
1.2.2. Gewählter Ansatz für die Fehlerprognose	10
1.3. Aufbau der Arbeit	12
2. Stand der Technik und Beitrag der Arbeit.....	15
2.1. Instandhaltungskonzepte für luftfahrttechnische Systeme	15
2.1.1. Zustandsbasierte Instandhaltung	17
2.1.2. Beitrag der Arbeit.....	19
2.2. Prognose der Lebensdauer für technische Systeme	19
2.2.1. Datenbasierte Ansätze.....	21
2.2.2. Modellbasierte Ansätze.....	22
2.2.3. Hybride Ansätze.....	23
2.2.4. Anwendungsmerkmale	23
2.2.5. Beitrag der Arbeit.....	25
3. Analyse von Zustandsüberwachungssystemen.....	27
3.1. Operatives Potential von Zustandsüberwachungssystemen.....	27
3.2. Modellierungsansatz für das deterministische Modell	29
3.3. Modellierungsansatz für das stochastische Modell	32
3.4. Zustandsüberwachung	35
3.4.1. Fehlerdiagnose	35
3.4.2. Fehlerprognose.....	39
3.5. Instandhaltung.....	40
3.5.1. Wartungsmaßnahmen.....	41
3.5.2. Reparaturzeiten	43
3.6. Ersatzteilversorgung.....	44
3.7. Modellvalidierung	45
3.7.1. Vorgehensweise	45
3.7.2. Verwendetes Szenario.....	48
3.7.3. Ergebnisse	49
3.8. Potentialanalyse der Zustandsüberwachung	51
3.8.1. Fehlerdiagnose	51
3.8.2. Fehlerprognose.....	52
3.8.3. Risikoanalyse für PBC-Konzepte	53
3.8.4. Zusammenfassung und Ausblick	54
4. Modellbasierte Systemidentifikation.....	56
4.1. Ansatz zur Implementierung.....	56
4.2. Genetische Programmierung	58
4.3. Rekursive Bayessche Schätzverfahren.....	60
4.4. Vorgehensweise für die modellbasierte Systemidentifikation	62
4.4.1. Genetische Programmierung mit integriertem Unscented Kalman Filter.....	63
4.4.1.1. Kombinierte Parameter- und Zustandsschätzung	65
4.4.1.2. Getrennte Parameter- und Zustandsschätzung.....	65
4.4.1.3. Auswahl der Filterauslegung für die Störgrößenschätzung	66
4.4.2. Bewertungskriterien der modellbasierten Systemidentifikation	67

4.4.3. Validierung der Bewertungskriterien.....	70
4.5. Hybrider Ansatz für Modellbasierte Systemidentifikation	73
4.5.1. Hybride Ansätze für Bayessche Schätzverfahren	73
4.5.1.1. Autonomous Multiple Model Schätzer	75
4.5.1.2. Cooperating Multiple Model Schätzer	76
4.5.2. Hybride Systemidentifikation	78
4.5.3. Modellbasierte Systemidentifikation mit hybridem Filteransatz	81
5. Hybride Fehlerprognose	83
5.1. Aufgaben der Fehlerprognose.....	83
5.1.1. Unterstützung von prädiktiven Maßnahmen.....	84
5.1.2. Auswahl eines geeigneten Kriteriums zur prädiktiven Planung	88
5.2. Propagierung von statistischen Eigenschaften	89
5.3. Anpassungen des GP-UKF für Prognose	90
5.3.1. Erweiterung der Bewertungskriterien zur Modellauswahl	90
5.3.2. Hybride Filterauslegung als Prognosefunktion.....	92
5.3.2.1. Datenbasiertes Prozessmodell.....	92
5.3.2.2. Anpassung der Filtergleichungen.....	95
5.3.3. Erweiterung zum Multiple-Model-Ansatz	99
5.3.4. Globale Korrektur zur Verbesserung der Prognosegüte	103
5.4. Implementierung des GP-UKF Prognosekonzeptes	105
6. Analyse der hybriden Fehlerprognose	108
6.1. Kriterien zur Bewertung der Prognosefähigkeit.....	108
6.1.1. Herleitung des Prognosehorizontes.....	110
6.1.2. Bewertung der Genauigkeit	111
6.1.3. Bewertung der Präzision	113
6.1.4. Bewertung des Konvergenzverhaltens.....	114
6.1.5. Zusammenfassung der Bewertungskriterien.....	115
6.2. Vorgehensweise zur Bewertung der Prognosefähigkeit.....	116
6.3. Simulierte Daten	119
6.3.1. Lineare Schadensmodelle	121
6.3.2. Exponentielle Schadensmodelle	130
6.4. Experimentelle Daten	135
6.4.1. Prüfstandsaufbau und Messdatenerfassung	138
6.4.2. Vorgehensweise zur Datenaufbereitung	140
6.4.3. Bewertung der Prognosefähigkeiten	142
6.5. Vergleich mit aktuellem Stand der Technik	149
6.5.1. Ergebnisse mit UKF-GAP	150
6.5.2. Vergleich von GP-UKF und UKF-GAP	153
6.6. Operationelles Potential des GP-UKF Prognosekonzeptes	155
6.7. Zusammenfassung der Ergebnisse.....	157
7. Zusammenfassung und Ausblick	160
7.1. Inhalt und Ergebnisse der Arbeit	160
7.2. Weiterführende Arbeiten	164
7.2.1. Weiterentwicklung des Maintenance Modells.....	164
7.2.2. Optimierung des GP-UKF-Ansatzes.....	164
Referenzen	167
Anhang A – Algorithmen	175
A.1 Implementierung der Genetischen Programmierung	175
A.2 Unscented Kalman Filter als Zustandsschätzer.....	176
A.3 Unscented Kalman Filter als Parameterschätzer.....	177
A.4 Unscented Kalman Filter kombinierte Parameter- und Zustandsschätzung	178
Anhang B – Formeln und Parameter	180
B.1 Statistische Momente von Zufallszahlen.....	180

B.2 Verteilungsformen Maintenance Modell.....	181
B.3 Varianzanteile Maintenance Modell.....	182
B.4 Konfiguration Genetische Programmierung.....	183
B.5 Parameter simulierte Degradierungsverläufe	184
Anhang C – Validierung und Verifikation	185
C.1 Validierung Maintenance Modell.....	185
C.2 Verifikation Prognose lineare Modelle	190
C.3 Verifikation Prognose exponentielle Modelle	192
Anhang D – Prüfstandskonfiguration	194
D.1 Lüfter AMETEK Rotron MAX50021 2900X7	194
D.2 Messdatenerfassung mit Beschleunigungssensoren KISTLER 8704B/4B50.....	195

VIII

Nomenklatur

Mathematische Funktionen

$\operatorname{argmax}\{\cdot\}$	Maximum der betrachteten Funktion
$\operatorname{argmin}\{\cdot\}$	Minimum der betrachteten Funktion
$\operatorname{cov}(\cdot)$	Kovarianz
$\Gamma(\cdot)$	Gammafunktion
$E[\cdot]$	Erwartungswert
$p(\cdot)$	Wahrscheinlichkeitsdichtefunktion
$\rho'(\cdot)$	Autokorrelation
σ_x	Standardabweichung der numerischen Größe x
σ_x^2	Varianz der numerischen Größe x
$\Phi(\cdot)$	Kooperationsfunktion für Multiple Model Ansätze
\bar{x}	Mittelwert der numerischen Größe x
$x_{0,5}$	Zentralwert der numerischen Größe x

Symbole

α_{FA}	Fehlalarmrate (0-0,5)
θ_{CBM}	Relativer Anteil von CBM Maßnahmen
β	Formparameter Weibullverteilung
γ_P	Relative Präzision der Prognose (0-1)
ε_D	Diagnosefehler
ε_P	Prognosefehler
ε_v	Time Averaged Normalized Innovation Square
E	Verlust an operationeller Zeit
θ_D	Relative Genauigkeit der Diagnose (0-1)
θ_P	Relative Genauigkeit der Prognose (0-1)
θ_M	Anteil von Turnaroundzeiten, der nicht automatisiert werden kann
κ_x	Fehlerfaktor logarithmische Normalverteilung der Zufallszahl x
λ	Austauschrate, bzw. Fehlerrate
λ_{eff}	Effektive Austauschrate, bzw. Fehlerrate
t_0	Startpunkt der Prognose

Modellgrößen

Δt	Diskrete Modellschrittweite
H	Transitionsmatrix
ξ	Störgröße
$\hat{\xi}$	Schätzwert für Störgröße ξ
P_{ξ}	Kovarianzmatrix der Schätzfehler für Modellgröße ξ
P_x	Kovarianzmatrix der Schätzfehler für Modellgröße x
Q	Kovarianzmatrix für Modellunsicherheiten
R	Kovarianzmatrix für Messunsicherheiten
x	Modellzustand
\hat{x}	Schätzwert für Modellzustand x

Abkürzungen

A_0	Operationelle Verfügbarkeit
AMM	Autonomous Multiple Model
BIT	Build-In-Test
CBM	Condition Based Maintenance
CI	Condition Indicator
CMM	Cooperating Multiple Model
COM	Condition Monitoring
EHM	Enhanced Health Management
EKF	Extended Kalman Filter
EoL	End of Life
EoP	End of Prediction
FN	False Negatives
FP	False Positives
FR	Füllrate
GC	Global Convergency
GP	Genetische Programmierung
GPB1	Generalized Pseudo Bayesian 1-ter Ordnung
GP-UKF	Genetische Programmierung mit integriertem Unscented Kalman Filter
ILMR	Inverse Logistic Maintenance Ratio
IMM	Interacting Multiple Model
LC	Local Convergency

LCC	Life Cycle Costs
LKF	Lineares Kalman Filter
LOG	Logistik
MAP	Maximum a Posteriori
MAPE	Mittlere prozentuale Fehler
MCR	Mission Capability Rate
MID	Maintenance Index
MMDL	Maintenance Model
MMSE	Minimum Mean-Square Error
MNT	Maintenance
MR	Mission Reliability
MTBF	Mean Time Between Failure
MTBSM	Mean Time Between Scheduled Maintenance
MTTM	Mean Time To Maintenance
MTTR	Mean Time To Repair
MWT	Mean Waiting Time
N_S	Anzahl an verschiedenen Startpunkten der Prognose für jeden Testlauf
N_T	Anzahl an verschiedenen Testläufen für Prognose
OCM	On Condition Maintenance
PA	Prognostic Accuracy
PBC	Performance Based Contracting
PE	Probability of Error
PH	Prognosehorizont
PoF	Probability of Failure
PP	Prognostic Precision
RMSE	Mittlerer quadratische Fehler
RMT	Reliability, Maintainability & Testability
RTFM	Run To Failure Maintenance
RUL	Remaining Useful Life
RUL*	Prognostizierte verbleibende Nutzungsdauer
SCR	Service Capability Rate
SSD	Sample Standard Deviation
T_0	Administrative Wartezeit bei jeder Instandhaltungsmaßnahme
T_L	Logistische Vorlaufzeit
T_M	Mittlere Missionszeit
TN	True Negatives

TP	True Positives
T_R	Mittlere Reparaturzeit
T_T	Mittlere Turnaroundzeit
T_W	Mittlere Wartezeit
UKF	Unscented Kalman Filter
UKF-GAP	Unscented Kalman-Filter mit integriertem Gauß-Prozess
UR	Utilization Rate
VSMM	Variable Structure Multiple Model
WPA	Weighted Performance Average

Abstract

This thesis deals with the analysis of the opportunities and challenges for improving the operational performance of aviation systems by the implementation of a condition-based maintenance concept. The first step is to illustrate how the implementation of diagnostic and prognostic functions affects availability and maintainability of the operating system. The main scope of this work is the evaluation and verification of a novel concept for failure prognosis.

Therefore the first aim of the work is to provide the evidence that the operational performance of aviation systems can be improved through predictive maintenance. A dedicated simulation environment has been built up and validated to support this task. By following a hierarchical modelling approach, it is possible to perform a holistic assessment of design requirements regarding accuracy and precision of diagnostic and prognostic functions. Furthermore modelling of the first two statistical moments of selected model properties enables a risk analysis for service-based contracts.

Motivated by the results of this analysis, the main scope of the work is the evaluation of a novel hybrid prognostic concept with data- and model-based parts. Therefore „*Genetic Programming*“ (GP) for system identification is extended by the „*Unscented Kalman Filter*“ (UKF) to integrate a model-based part into the data-based approach (GP-UKF). It is further verified that if appropriate training data is provided, the GP-UKF enables a robust and reliable failure prognosis without the need for any prior knowledge about the underlying process. The motivation to provide such capabilities results from the need to reduce the effort and costs for newly developed prognostic capabilities. The high development effort of such capabilities during the design phase of new systems and the limited quality of existing prognostics for flying systems in service did allow only very few areas of successful application.

Simulation models for generation of degradation paths under consideration of measurable and non-measurable effects are developed to support the verification of the GP-UKF. In addition an appropriately instrumented test rig has been used to generate experimental data. The assessment of the prognostic capabilities of the GP-UKF is mainly facilitated by the simulated data, which provide a wide spectrum of different types of degradation. The experimental part of the GP-UKF verification is based on test runs with seeded bearing degradation for an airworthy fan. An objective assessment of the GP-UKF is achieved by comparison with an established concept for hybrid failure prognosis. In conclusion the operational potential of the GP-UKF is evaluated by applying the results from the quantitative assessment as input to the validated simulation environment for potential analysis of prognostic functions.

Zusammenfassung

Die vorliegende Arbeit beschäftigt sich mit der Analyse der Möglichkeiten und Herausforderungen zur Steigerung der operationellen Leistungsfähigkeit von Luftfahrtsystemen durch zustandsbasierte Wartungskonzepte. Hierfür wird zunächst der Einfluss von Diagnose- und Prognosefunktionen auf die Verfügbarkeit und den Wartungsaufwand des operativen Systems dargestellt. Das Hauptziel der Arbeit ist nachfolgend die Analyse und Verifikation eines neuen Konzeptes zur Fehlerprognose.

Die erste Zielsetzung ist hierbei die Nachweisführung, dass prädiktive Instandhaltungskonzepte die operationelle Leistungsfähigkeit von Luftfahrtsystemen steigern können. Hierfür wurde eine speziell für diesen Zweck ausgelegte Simulationsumgebung aufgesetzt und validiert. Ein hierarchischer Modellierungsansatz ermöglicht eine ganzheitliche Bewertung von Auslegungskriterien hinsichtlich Genauigkeit und Präzision von Diagnose- und Prognosefunktionen. Durch die Modellierung der ersten beiden statistischen Momente ausgewählter Modellanteile wird weiterführend eine Risikoanalyse für leistungsorientierte Vertragskonzepte ermöglicht.

Motiviert durch die Ergebnisse dieser Analyse wird als Hauptziel der Arbeit ein hybrides Prognosekonzept mit daten- und modellbasierten Anteilen untersucht. Hierzu wird die „*Genetische Programmierung*“ (GP) als datenbasiertes Verfahren zur Systemidentifikation durch das „*Unscented Kalman Filter*“ (UKF) um einen modellbasierten Anteil erweitert (GP-UKF). Es wird gezeigt, dass der GP-UKF durch die Bereitstellung von geeigneten Trainingsdaten, ohne Vorwissen über den zu prognostizierenden Prozess eine robuste und zuverlässige Fehlerprognose ermöglicht. Die Motivation hierfür resultiert aus den komplexen und kostenintensiven Maßnahmen zur Neuentwicklung von Prognosefähigkeiten, die durch den hiermit verbundenen hohen Aufwand in der Entwicklungsphase und die begrenzte Qualität der Prognose in der Nutzungsphase bisher in fliegenden Systemen nur für einen sehr begrenzten Anwendungsbereich eine erfolgreiche Nutzung zugelassen haben.

Für die Verifikation des GP-UKF werden Modelle zur Simulation von Degradierungsverläufen unter Berücksichtigung von messbaren und nicht messbaren Einflussgrößen aufgestellt und zusätzlich ein speziell instrumentierter Prüfstand genutzt. Die Simulationsmodelle ermöglichen die Analyse eines breiten Spektrums an Anwendungsfällen zur Bewertung der Prognosefähigkeiten des GP-UKF. Für den experimentellen Anteil der Verifikation wird das Degradierungsverhalten von Wälzlagern eines luftfahrttauglichen Lüfters analysiert und prognostiziert. Der Vergleich mit einem etablierten Verfahren aus dem Bereich der hybriden Fehlerprognose ermöglicht schließlich eine objektive Bewertung des untersuchten Prognoseansatzes. Abschließend werden die Ergebnisse der quantitativen Bewertung verwendet, um mittels der validierten Simulationsumgebung für Potentialanalysen von Prognosefunktionen eine Analyse des operationellen Nutzens des GP-UKF-Ansatzes vorzunehmen.

1. Einleitung

In dieser Arbeit wird zunächst die Motivation zur Unterstützung von prädiktiven Instandhaltungskonzepten durch eine modellbasierte Analyse der Einflüsse von Diagnose & Prognose auf die Systemverfügbarkeit von Luftfahrtsystemen dargestellt. Weiterführend wird im Hauptteil ein neuer Ansatz zur hybriden Fehlerprognose vorgestellt, der ausgewählte Konzepte aus dem Bereich der Systemidentifikation und adaptiven Filterung kombiniert, um ohne vorherige Kenntnis über die physikalischen Zusammenhänge von Degradierungsprozessen technischer Systeme eine hybride Fehlerprognose mit modellbasierten Anteilen für diese zu ermöglichen. Die Fähigkeit zur Fehlerprognose wird anhand von synthetischen und experimentellen Datensätzen durch die Anwendung von geeigneten Bewertungskriterien für Prognosekonzepte untersucht und verifiziert.

In diesem Abschnitt wird zunächst eine Übersicht über die Zusammenhänge zwischen zustandsbasierter Instandhaltung und den dafür benötigten Fähigkeiten zur Diagnose & Prognose gegeben. Nachfolgend werden die dadurch motivierten Zielsetzungen und die zur Umsetzung gewählte Vorgehensweise erläutert sowie der Aufbau der Arbeit beschrieben.

1.1. Motivation

Der Markt für die zivile und militärische Luftfahrt weist zunehmend einen Bedarf an serviceorientierten Vertragskonzepten („*Performance Based Contracting*“ - PBC) auf¹. Bei PBC-Konzepten findet durch die Zusicherung von Leistungsmerkmalen über eine definierte Nutzungsdauer auch nach der Inbetriebnahme eine Teilung des Kostenrisikos zwischen Nutzer und Hersteller statt. Am zivilen Markt stellen hauptsächlich die ausgeprägte Konkurrenzsituation und der ständig wachsende Markt Antriebe zur Entwicklung hierfür geeigneter Geschäftsmodelle dar. Der globale Wettbewerb gewinnt zwar auch im militärischen Sektor zunehmend an Bedeutung, jedoch ist das nur quartalsweise verfügbare Kapital der meist öffentlichen Kunden auf zusätzliche Weise ein bestimmender Faktor. Um hierbei trotz begrenzter Budgets auch Raum für Neuentwicklungen zu lassen, müssen die Entwicklungs- und Betriebskosten aktueller und zukünftiger Vorhaben möglichst minimiert werden und planbar sein. Die kontinuierliche Realisierung von Neuentwicklungen ist hierbei sowohl für den Hersteller als auch für den Nutzer zur strategischen Ausrichtung und nachhaltigen Sicherung der eigenen Position unerlässlich. Neben der daraus resultierenden Forderung nach einer Minimierung aller anfallenden Kosten für Entwicklung und Betrieb, ist zum Erhalt der Konkurrenzfähigkeit aber gleichzeitig die Bereitstellung von technologisch anspruchsvollen Systemen erforder-

¹ Selbst die USAF mit dem größten Verteidigungsbudget der Welt fordern diese Vertragsart zur Kostenersparnis seit einigen Jahren gezielt an [8]. In der zivilen Luftfahrt gehören ausdifferenzierte Servicekonzepte wie etwa das On-Board Telekommunikationssystem „*Airbus GSM-On-Board-System*“ bereits zur gängigen Praxis. Triebwerkshersteller bieten häufig sogar ihr komplettes Produkt als Serviceleistung an („*Power by the Hour*“).

lich. Die wesentlichen Leistungsmerkmale eines hierfür geeigneten PBC-Konzeptes lassen sich somit durch Kosteneffizienz und operationelle Leistungsfähigkeit beschreiben, wobei die jeweiligen Vertragsinhalte anwendungs- und plattformspezifisch definiert werden müssen. Die erfolgreiche Umsetzung eines derartigen Modells erfordert dessen Berücksichtigung bereits in der Konzept- und Designphase².

Auslegungskriterien, wie ein entsprechend des angestrebten Nutzungsprofils optimiertes Design oder kostenoptimierte Mindestanforderungen an die Zuverlässigkeit und Wartungsfreundlichkeit, bilden hierfür lediglich eine notwendige Grundlage. Des Weiteren erfordert die Einhaltung der zugesicherten Leistungsmerkmale während der Vertragslaufzeit eine geeignete Strategie zum Erhalt der Sicherheit und Betriebsfähigkeit [1]. Hierzu zählen im Wesentlichen die Vorgehensweise bei Modifikationen und Upgrades sowie die verfolgte Instandhaltungsphilosophie. Der Handlungsrahmen bei den genannten Aspekten wird bereits in der Systemauslegungs- und Zulassungsphase maßgeblich festgelegt und muss unter den beteiligten Parteien vertraglich abgestimmt sein. Der Bedarf für Modifikationen zur Problembehebung oder Upgrades zur Verbesserung der Leistungsfähigkeit, bzw. Anpassung an spezifische Anforderungen, ist zwar gängige Praxis und bei der Entwicklung von Geschäftsmodellen fest eingeplant, hat aber aufgrund des nicht kontinuierlichen Bedarfes im Vergleich zum Wartungskonzept geringe Auswirkungen auf die ökonomische und operationelle Effizienz des betrachteten Systems.

Die Strategie zur Instandhaltung und bedarfsgerechten Bereitstellung von Verbrauchsgütern dient neben dem eigentlichen Systemdesign als wesentlicher Faktor zur Beeinflussung der Betriebskosten und Systemverfügbarkeit [2]. Die Bandbreite der benötigten Verbrauchsgüter für ein fliegendes System stellt aufgrund der Systemkomplexität, dem vielfältigen Einsatzspektrum sowie den Richtlinien und Zulassungsvorschriften für den Luftfahrtverkehr enorme Anforderungen an die Logistik. Für den zivilen Sektor mit seiner hohen Abdeckungsdichte des globalen Flugverkehrs sind diese ungleich komplexer als für den militärischen Bereich mit räumlich und zeitlich begrenzten Einsatzgebieten. Aufgrund von standardisierten Betriebsstoffen (Kraftstoffe, Hydrauliköle, Kühl- und Reinigungsmittel etc.) und der damit gewährleisteten Austauschbarkeit für verschiedene Flugzeugmuster und Nutzer, lässt sich der Bedarf hierfür in der Regel zuverlässig befriedigen [3]. Eine größere Herausforderung stellt die bedarfsgerechte und kostenoptimierte Versorgung mit Ersatzteilen und Fachpersonal dar [4], [2]. Nahezu jeder Flugzeugtyp hat aufgrund der unterschiedlichen Systemauslegungen und Nutzungsweisen einen ganz individuellen Bedarf an Einzelkomponenten und geschultem Personal zur Inspektion und Instandhaltung. Zur Minimierung dieser Problematik wird bei der

² Bereits vor dem eigentlichen Systemdesign ist für PBC zur Erstellung eines geeigneten Geschäfts- und Finanzierungsmodells die Einbindung aller Interessensvertreter (Hersteller, Systemintegrator(en), Lieferanten, Instandhaltungsunternehmen, Zulassungsbehörden, Kunden, politische Interessensgemeinschaften etc.) erforderlich [1].

Systemauslegung deshalb im Rahmen von Familienkonzepten auf eine möglichst hohe Austauschbarkeit von Gerät und Fachpersonal geachtet. Zwar lässt sich diesem Anspruch für Mensch-Maschine Schnittstellen wie z.B. Cockpit, Kommunikationseinheiten oder Be- und Entlademechanismen häufig gerecht werden aber ein entsprechend des Nutzungsprofils optimiertes Design zur Reduzierung der Betriebskosten und Gewährleistung von individuellen Leistungsmerkmalen erfordert in der Regel auch individuelle Auslegungsphilosophien der technischen und strukturellen Systeme. Somit stellt die Gewährleistung von benötigten Ersatzteilen und Fachpersonal für einen globalen Markt am richtigen Ort und zur richtigen Zeit, ohne hierbei den geforderten Bedarf zu überdecken und damit vermeidbare Personal-, Produktions-, Lager- und Logistikkosten zu generieren, eine zentrale Herausforderung zur erfolgreichen Umsetzung von PBC-Konzepten dar [5]. Die Realisierung von leistungsfähigen Zustandsüberwachungskonzepten und darauf aufbauenden Fähigkeiten zur zuverlässigen Bedarfsvorhersage für Ersatzteile und entsprechendem Personal, sind hierbei als Schlüsselfaktoren identifiziert worden [6], [7]. Diese Aussage soll im Folgenden unter Berücksichtigung der beiden Aspekte Kosteneffizienz und operationelle Leistungsfähigkeit mit Bezug zur Instandhaltungsphilosophie weiter veranschaulicht werden.

1.1.1. Kosteneffizienz

Die gesamten Kosten zur Entwicklung, Bereitstellung und Nutzung eines Luftfahrtsystems von der Konzeptphase bis zur Außerbetriebnahme, werden als „*Life Cycle Costs*“ (LCC) definiert. Während ein Großteil der LCC (~60%) in der Nutzungsphase anfällt, wird der absolut zu erwartende Wert im Wesentlichen (~95%) während der Konzept- und Designphase festgelegt [9]:




Abbildung 1: LCC Festschreibung und Verteilung für Luftfahrtsysteme

Somit bieten Maßnahmen mit Auswirkungen auf die anfallenden Kosten während der Nutzungsphase zwar das größte Potential zur Beeinflussung der LCC, jedoch sind bestimmte fortlaufende

Kostenanteile der Nutzungsphase für z.B. Verbrauchsgüter, Gebühren und Personal etc., nur begrenzt beeinflussbar³. Der Bereich der Instandhaltung bietet im Vergleich hierzu die Möglichkeit zur direkten Kostenersparnis mit nahezu vollständig steuerbaren Abhängigkeiten und Verantwortlichkeiten (z.B. Garantiehaftung, Kompetenzenteilung und Wartungskonzept etc.).

Nach [4] ergeben sich durch Diagnose und Prognose mehrere Aspekte, wie die Systeminstandhaltung durch eine Zustandsüberwachung und Bedarfsvorhersage für Betriebsmaterialien und Fachpersonal unterstützt werden kann:

Nº	Potential Diagnose (D) und Prognose (P)
(i)	Erhöhung der Fehlererkennungs- und isolationsfähigkeit während des Betriebes oder auf möglichst niedriger Wartungsebene ⁴ und damit auch Reduzierung der Sekundäreffekte (D)
(ii)	Reduzierung der „ <i>Cannot Duplicate</i> “- bzw. „ <i>No Fault Found</i> “-Raten und damit auch Reduzierung der Sekundäreffekte (D)
(iii)	Reduzierte Anforderungen an das logistische System durch Kenntnis über die benötigte Art, Anzahl und den Bedarfszeitpunkt von Ersatzteilen und Fachpersonal (P)
(iv)	Zuverlässigere Fehlerisolation und damit auch eine reduzierte Anzahl der möglichen Ursachen bei nicht eindeutig zuordnungsfähigen Fehlermeldungen (D)
(v)	Potential zur Einsparung von Personal- und Materialaufwand durch automatisierte Integrationschecks nach Durchführung einer Wiederinstandsetzungsmaßnahme (D)
(vi)	Reduzierung der Anforderungen an die Bereitstellung von „ <i>Build-In-Test-Equipment</i> “ und „ <i>Ground Test Equipment</i> “ sowie zur Handhabung benötigtes Fachpersonal (D)
(vii)	Reduzierung der notwendigen Inspektionen und präventiven Wartungsmaßnahmen ⁵ (D & P)
(viii)	Erhöhung der Betriebsdauer für „ <i>Time Change Items</i> “ durch Kenntnis über den wirklichen Zustand ⁶ (D & P)
(ix)	Reduzierung der Fehlerfälle im Betrieb durch Vorhersage des Ausfallzeitpunktes und damit auch Reduzierung der Sekundäreffekte (P)

Tabelle 1: Potentiale zur Steigerung der Kosteneffizienz mittels Diagnose und Prognose

³ Diese Parameter lassen sich im Wesentlichen durch das Systemdesign (z.B. Leermasse, spezifischer Kraftstoffverbrauch etc.) optimieren, da die Festlegung von weiteren hierfür relevanten Faktoren wie Tarifverträge, Kraftstoffpreise, Gebühren und Steuern weitestgehend außerhalb des Einflussgebietes der Hersteller liegen.

⁴ Es wird zwischen zwei- bis vierstufigen Wartungskonzepten unterschieden, wobei die Möglichkeiten zur Instandsetzung, aber auch der logistische und technische Aufwand, mit dem Wartungsniveau zunehmen [13], [14], [15].

⁵ Diese Fähigkeit erfordert besonders für sicherheitsrelevante Aspekte einen erhöhten Aufwand im Rahmen der Zertifizierung und eine gewisse Betriebsdauer bis die Zuverlässigkeit nachgewiesen wurde.

⁶ Time Change Items sind Bauteile, die nach einer definierten Betriebsdauer ausgetauscht werden. Um die Sicherheit im Betrieb zu gewährleisten, werden diese Intervalle mit hohen Sicherheitsfaktoren versehen (z.B. 6x9-Strategie für Strukturbauteile oder Verlust von bis zu 20% der möglichen Betriebsdauer für Wälzlager [16]).

Prinzipiell sollen alle diese Aspekte einem übergeordneten Ziel dienen:

Reduzierung der LCC durch erhöhte Design- und Akquisitionskosten (Entwicklung und Integration der benötigten Fähigkeiten und Prozesse) sowie zusätzlicher operativer Unterstützung zur Auswertung und Nutzung der generierten Informationen, jedoch einer relativ dazu weitaus größeren Reduzierung der Kosten für Instandhaltung und Logistik und einer zusätzlichen Steigerung der Verfügbarkeit des operativen Systems [10]⁷.

Um das Potential der genannten Aspekte in vollem Umfang nutzen zu können, ist ein geeignetes Systemdesign und eine entsprechende Instandhaltungsstrategie erforderlich. Eine der wesentlichen Herausforderung besteht hierbei in der technischen Realisierung der Zustandsüberwachungs- und Fehlerprognosefähigkeiten als Teil der Systemauslegung sowie deren Zertifizierung zur Unterstützung eines ökonomisch relevanten oder sicherheitskritischen Instandhaltungsprozesses. Die Ergebnisse der möglichst automatisierten Zustandsüberwachung müssen zur Reduzierung der Arbeitsbelastung für den Nutzer entsprechend aufbereitet und bereitgestellt werden. Des Weiteren ist zur Gewährleistung der Verfügbarkeit des operativen Systems und Minimierung des Aufwandes für das betreuende Personal sowie zur optimierten Steuerung der Herstellungs- und Logistikprozesse eine bedarfsgerechte und somit dynamische Organisation der durchzuführenden Maßnahmen erforderlich [11]. Auch die hierfür benötigten Fähigkeiten und Prozesse müssen entsprechend den Anforderungen der luftfahrttechnischen Zulassungsbehörden implementiert werden und stellen ein ebenso komplexes Aufgabenfeld wie die Entwicklung der eigentlichen Diagnose- und Prognosefähigkeiten dar. Nur im erfolgreichen Zusammenspiel all dieser Elemente kann das volle Potential einer bedarfsgerechten Material- und Personalplanung genutzt werden.

1.1.2. Operationelle Leistungsfähigkeit

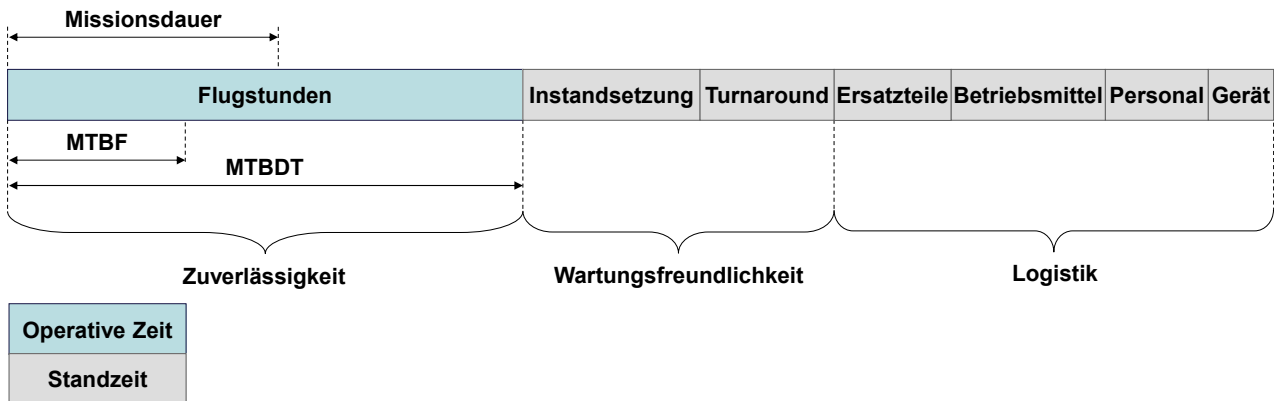
Im Rahmen der Aufstellung von geeigneten Entwicklungs- und Betreibermodellen zur Umsetzung von PBC-Konzepten sind im Wesentlichen die folgenden Parameter als relevante und messbare Größen zur Quantifizierung der operationellen Leistungsfähigkeit identifiziert worden [12]:

- *Operational Availability* (A_0): Verfügbarkeit des Systems [%]
- *Mission Capability Rate* (MCR): Missionsfähigkeit des Systems [%]
- *Mission Reliability* (MR): Anteil der erfolgreich abgeschlossenen Missionen [%]

Für die resultierende Verfügbarkeit sind maßgeblich die Aspekte Zuverlässigkeit, Wartungsfreundlichkeit und Logistik bestimmend. Für eine ökonomische Nutzung sollte das System möglichst kontinuierlich betrieben werden.

⁷ Der Optimierungsspielraum ist proportional zur Nutzungsdauer des Systems und bietet somit bei Luftfahrtsystemen, die durchschnittlich einen Lebenszyklus von ca. 30 Jahren haben, ein entsprechendes Potential.

Es ergibt sich folgende Aufschlüsselung der unterschiedlichen Anteile zur Abschätzung der operationellen Verfügbarkeit:



MTBF: Mittlere Zeit zwischen zwei unkritischen Vorfällen

MTBDT: Mittlere Zeit zwischen zwei Betriebsunterbrechungen

Abbildung 2: Anteile zur Abschätzung der operationellen Verfügbarkeit von Luftfahrtsystemen

Für einen gegebenen Systementwurf lässt sich die über einen längeren Einsatzzeitraum erreichbare Verfügbarkeit schließlich mittels (1.1) abschätzen [17]:

$$A_0 = \frac{\sum_t \text{Zuverlässigkeit}}{\sum_t \text{Zuverlässigkeit} + \sum_t \text{Wartungsfreundlichkeit} + \sum_t \text{Logistik}} \cdot 100 \quad (1.1)$$

Aus diesen Zusammenhängen ist ersichtlich, dass die in § 1.1.1 genannten Aspekte mit Auswirkungen auf die Zuverlässigkeit, Wartungsfreundlichkeit und Logistik zu einer Steigerung der operationellen Leistungsfähigkeit beitragen können. Alle hierfür relevanten Annahmen sind aufbauend auf den Inhalten von § 1.1.1 in Tabelle 2 zusammengefasst. Die Leistungsparameter MCR und MR hängen im Wesentlichen über die kritische Fehlerrate, bzw. die Häufigkeit eines Missionsabbruchs und die Systemverfügbarkeit miteinander zusammen. Für ein gegebenes Systemdesign wird das durch Diagnose- und Prognosefähigkeiten erreichbare Verbesserungspotential für die operationelle Leistungsfähigkeit von der jeweiligen Ausgangssituation, dem betrachteten Szenario und der Integrität des Zustandsüberwachungssystems bestimmt⁸. Um die Verfügbarkeit nicht negativ zu beeinflussen, müssen Diagnose und Prognose Mindestanforderungen hinsichtlich Zuverlässigkeit (z.B. maximale Fehlalarmrate oder Robustheit der Fehlerprognose) und Genauigkeit (z.B. Bestimmung der Schadensgröße oder Vorhersage des Ausfallzeitpunktes) erfüllen⁹.

⁸ Ein Beispiel liefert die F/A-18C Flotte aus dem Jahr 1999: Ausgehend von einer Fehlalarmrate der Flugsteuerungsaktuatorik von 75%, die innerhalb von 6 Monaten zu 85639 Mannstunden und 2,96 Jahren Standzeit führte, konnte durch die Optimierung der Fehlerisolation die Zeit zwischen zwei Fehlalarmen von 1,2 auf 52,7 Stunden erhöht werden [18].

⁹ Theoretische Untersuchungen haben ergeben, dass die Effizienz eines Instandhaltungskonzepts mittels Diagnose- und Prognosemaßnahmen um bis zu 15% gesteigert werden kann [19].

Nº	Potential Diagnose (D) und Prognose (P)	Zuverlässigkeit	Wartung	Logistik
(i) (iv)	Verbesserte Fehlererkennung- und isolationsfähigkeit (D)	Reduzierung der möglichen Sekundäreffekte ¹⁰	Reduzierung der Ursachen und des Aufwandes für Fehlerisolation	-
(ii)	Reduzierung der Ereignisse „ <i>Cannot Duplicate</i> “ und „ <i>No Fault Found</i> “ (D)	Reduzierung der Vorfälle und der Sekundäreffekte	-	Reduzierter Aufwand für Material und Personal sowie Logistik
(iii) (ix)	Vorhersage des Ausfallzeitpunktes (P)	Reduzierung der Vorfälle im Betrieb und der Sekundäreffekte	-	Bessere Planung zur Versorgung mit Ersatzteilen und Personal
(v)	Automatisierte Integrationschecks (D)	-	Reduzierter Aufwand für Wiederinbetriebnahme	Reduzierter Aufwand für Material und Personal sowie Logistik
(vi)	Reduzierte Anforderungen an „ <i>Build-In-Test</i> “ und „ <i>Ground Test Equipment</i> “ (D)	-	Reduzierter Aufwand für Fehlerisolation	Reduzierter Aufwand für Material und Personal sowie Logistik
(vii)	Reduzierte Inspektionen und präventive Wartungsmaßnahmen (D & P)	Reduzierung der Turnaroundzeit ¹¹ und Sekundäreffekte	Reduzierter Bedarf an Wartungsmaßnahmen	Reduzierter Aufwand für Material und Personal sowie Logistik
(viii)	Erhöhung der Betriebsdauer (D & P)	Reduzierung der Sekundäreffekte	Reduzierter Bedarf an Wartungsmaßnahmen	Reduzierter Bedarf an Ersatzteilen

Tabelle 2: Potentiale zur Steigerung der Systemverfügbarkeit mittels Diagnose und Prognose

1.1.3. Zusammenfassung

Die Implementierung von hinreichend zuverlässigen Diagnose- und Prognosefähigkeiten kann ein PBC-Konzept unterstützen. Als wesentliches Merkmal zeigt sich, dass bereits die Erhöhung der Diagnosekapazitäten auf verschiedenste Weise zur Steigerung der Kosteneffizienz und operationellen Leistungsfähigkeit beitragen kann. Eine zusätzliche Optimierung der Verfügbarkeit und Reduzierung der Anforderungen an das logistische System kann mittels Prognosefähigkeiten erzielt werden. Um das volle Potential solcher Konzepte nutzen zu können, ist zusätzlich eine geeignete Instandhaltungsstrategie erforderlich. Die hiermit erreichbare Verbesserung der ökonomischen und

¹⁰ Sekundäreffekte können entweder durch Fehler (Beschädigungen weiterer Bauteile oder Komponenten durch Fehlerfälle) oder Wartungsmaßnahmen (falsche Vorgehensweise für Transport, Lagerung oder Einbau) verursacht werden.

¹¹ Diese Fähigkeit erfordert einen erhöhten Aufwand im Rahmen der Zertifizierung, da die Pre-, Post- und Through-flight Checks einen wesentlichen Beitrag zur Flugsicherheit liefern.

operationellen Eigenschaften des fliegenden Systems hängt von der Leistungsfähigkeit des Zustandsüberwachungssystems, den Fähigkeiten zur Auswertung und Nutzung der Informationen sowie dem eigentlichen Systementwurf und operationellen Szenario ab. Zur erfolgreichen Realisierung ist die Berücksichtigung bereits in der Konzept- und Entwicklungsphase erforderlich.

1.2. Zielsetzung und Vorgehensweise

Die übergeordnete Zielsetzung der Arbeit besteht darin, den Bedarf und Nutzen von zustandsbasierten Instandhaltungskonzepten darzustellen und Methoden zur Umsetzung für Luftfahrtsysteme zu analysieren. Der Schwerpunkt liegt hierbei auf der Untersuchung der Möglichkeiten zur Realisierung einer prädiktiven Instandhaltung (s. § 2.1 für eine Einführung in die Thematik der verschiedenen Instandhaltungsstrategien). Für die Begründung des damit verbundenen erhöhten Entwicklungsaufwandes soll zunächst der operationelle Mehrwert einer prädiktiven Instandhaltung aufgezeigt werden. Hierfür wird im ersten Teil dieser Arbeit ein modellbasierter Ansatz hergeleitet, um eine Potentialanalyse von Zustandsüberwachungssystemen zu ermöglichen. Das Ziel der Analyse ist den Nutzen von Fehlerprognose zur Unterstützung prädiktiver Instandhaltung anhand der damit erreichbaren Steigerung der Systemverfügbarkeit und Wartungsfreundlichkeit deutlich zu machen.

Da der Fokus auf der Untersuchung der technischen Möglichkeiten zur Unterstützung eines Entwicklungsprozesses für Zustandsüberwachungssysteme und der Implementierung von Prognosefähigkeiten liegt, werden planungs- oder zulassungstechnische Aspekte nicht näher betrachtet.

Das Primärziel der Arbeit ist weiterführend die Implementierung eines neuen Konzeptes zur Fehlerprognose für luftfahrttechnische Systeme, das auch bei reduzierter Verfügbarkeit und Qualität von Trainingsdatensätzen und ohne vorherige Kenntnis von geeigneten Schadensmodellen eine prädiktive Instandhaltung zuverlässig unterstützen kann. Hiermit soll eine Möglichkeit aufgezeigt werden, Fehlerprognose auch für neue Systeme zur Verfügung zu ermöglichen, ohne problemspezifische und kostenintensive Lösungen entwickeln zu müssen.

1.2.1. Modellbasierte Potentialanalyse von Zustandsüberwachungssystemen

Die elementare Zielsetzung bei der Implementierung des modellbasierten Ansatzes („*Maintenance Model*“ - MMDL) war die Berücksichtigung der Anforderungen für Diagnose- und Prognosefunktionen bei der Analyse der operativen Leistungsfähigkeit von Luftfahrtsystemen. Zusätzlich sollte ein Risikomanagement für PBC-Konzepte unterstützt werden können. Ausgangspunkt war der Bedarf, einen Zusammenhang zwischen Auslegungsanforderungen von Zustandsüberwachungssystemen und Leistungskennzahlen des operativen Systems herzustellen. Hierzu wurde als Grundlage eine Simulationsumgebung erarbeitet, die alle relevanten Parameter einer Systemauslegung hinsichtlich Zuverlässigkeit, Wartungsfreundlichkeit und Versorgungskonzept miteinander verknüpft, um die erreichbare Systemverfügbarkeit abzuschätzen. Neben der rein deterministischen Vorgehensweise

zur Bestimmung von Erwartungswerten sollten hierbei auch Unsicherheiten im Systementwurf und Betreiberkonzept für eine PBC-Risikoanalyse berücksichtigt werden können. Entsprechend der Motivation für diese Arbeit war das nächste Ziel die Bewertung von Fehlerdiagnose- und prognosefähigkeiten. Hierfür wurde bei der Entwicklung der Simulationsumgebung darauf geachtet, Eingabegrößen zu berücksichtigen, die einen funktionalen Zusammenhang zwischen Eigenschaften wie der Güte und Fehlalarmrate der Diagnose sowie Genauigkeit und Präzision der Prognose und der erreichbaren Systemverfügbarkeit, bzw. Wartungsfreundlichkeit herstellen. Für die Modellvalidierung wurde eine zertifizierte Umgebung zur Bedarfsanalyse von Ersatzteilen und Simulation der operativen Verfügbarkeit genutzt. Das verwendete Szenario bildet ein generisches unbemanntes Luftfahrtssystem mit hinreichender Komplexität ab. Das validierte MMDL wurde verwendet, um das operative Potential eines Systemdesigns und Instandhaltungskonzeptes mit Prognosefähigkeiten im Vergleich zu einem Konzept ohne Zustandsüberwachung sowie mit Zustandsüberwachung aber ohne Möglichkeiten zur Fehlerprognose zu analysieren. Ausgehend von den Ergebnissen werden die Arbeiten zur Implementierung des Prognoseansatzes begründet.

Die Vorgehensweise der genannten Arbeiten ist in Abbildung 3 strukturiert dargestellt:

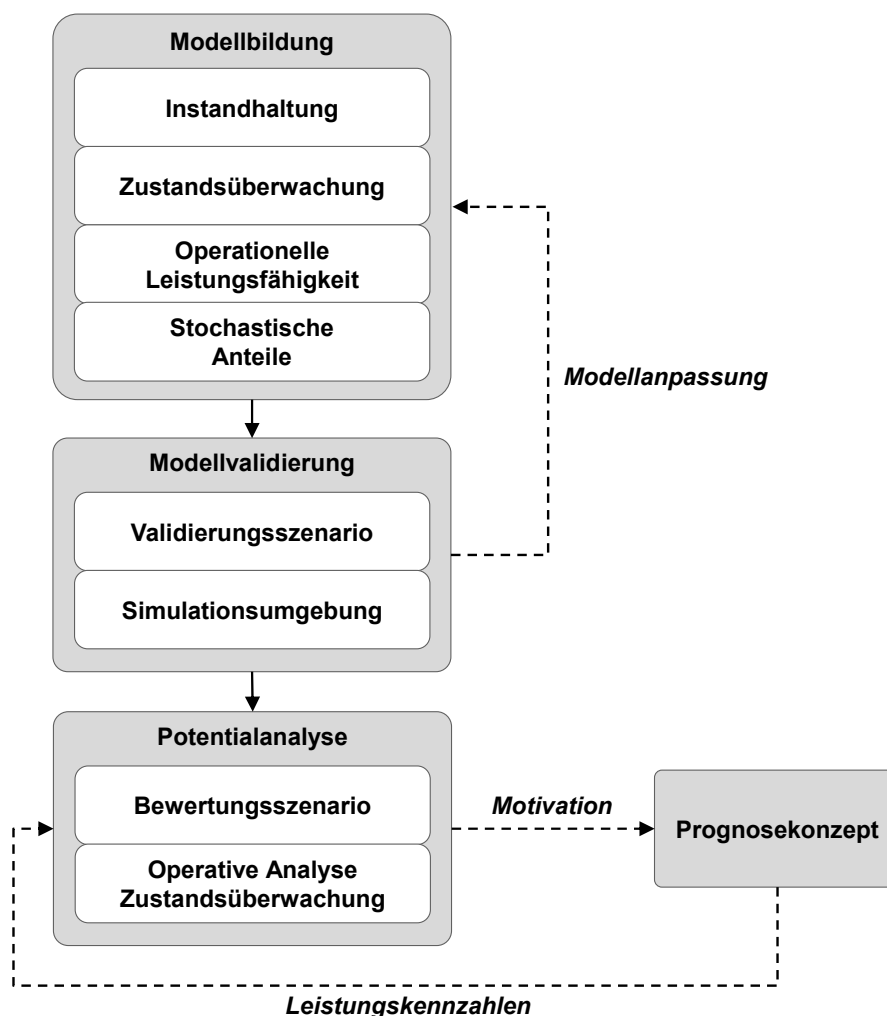


Abbildung 3: Vorgehensweise zur operativen Potentialanalyse von Zustandsüberwachungssystemen

1.2.2. Gewählter Ansatz für die Fehlerprognose

Aus einer umfassenden Literaturstudie und darauf aufbauenden Auswertung der bisher bekannten Ansätze für Fehlerprognose und den Herausforderungen, die sich für reale Anwendungen in diesem Bereich hinsichtlich der benötigten Zuverlässigkeit und Anwendbarkeit ergeben, wurden im Rahmen von Voruntersuchungen qualitative Anforderungen an ein Prognosekonzept abgeleitet:

- Das Prognosekonzept soll die Prognose zu jedem Zeitpunkt (auch ohne Verfügbarkeit von umfassenden Trainingsdatensätzen) ermöglichen.
- Das Prognosekonzept soll die Möglichkeit bieten, seine Leistungsfähigkeit kontinuierlich zu verbessern.
- Für die Prognose soll die Auswertung unterschiedlicher Nutzungsprofile möglich sein.
- Die Bestimmung eines Indikators für die zu prognostizierende Schadensgröße („*Condition Indicator*“ - CI) ist Aufgabe eines Diagnosesystems und nicht Teil des Prognosekonzeptes. Die Unsicherheiten bei der Bestimmung des CIs müssen mit in die Prognose einfließen können.
- Die Bestimmung der verbleibenden Nutzungsdauer soll auch bei nicht eindeutig definierten Grenzwerten der maximal zulässigen Schadensgröße möglich sein.
- Der Prozess zur Erlangung der Prognosefähigkeiten sowie die Prognose selber müssen nicht echtzeitfähig sein.
- Das Prognosekonzept soll die Möglichkeit bieten, beliebige Arten von Schadensverläufen zu handhaben und nicht auf eine bestimmte Art von Degradierungsprozessen beschränkt sein.
- Die Prognose soll Unsicherheiten bei der Bestimmung des Ausfallzeitpunktes angeben und damit eine Risikoanalyse für die Planung von Instandhaltungsmaßnahmen ermöglichen.
- Die Analyse von ausgewählten Kriterien soll die Bewertung der Leistungsfähigkeit sowie die Zuverlässigkeit der Prognose ermöglichen.
- Die Nutzung von messbaren und nicht messbaren Einflussgrößen soll ermöglicht werden.
- Die Wiederverwendbarkeit von erlernten Fähigkeiten soll gewährleistet werden.
- Die Ergebnisse der Prognose sollen reproduzierbar sein, um die Zertifizierbarkeit des Ansatzes sicher zu stellen.

Aus diesen Rahmenbedingungen hat sich die Notwendigkeit ergeben, einen modellbasierten Ansatz zu entwickeln, der bei Erweiterung der vorhandenen Datenbasis ohne manuelle Interaktion kontinuierlich verbessert werden kann und nicht hinsichtlich bestimmter Schadensverläufe limitiert ist.

Zur Umsetzung wurde ein neuer hybrider Ansatz gewählt, der eine datenbasierte Systemidentifikation („*Genetische Programmierung*“ - GP) mit einem modellbasierten Zustandsschätzer für nichtlineare Systeme („*Unscented Kalman Filter*“ - UKF) kombiniert (GP-UKF).

Durch einen *Multiple Model*-Ansatz wird die Herleitung von lokal optimierten Modellen ermöglicht und mittels des UKFs werden nicht messbare Einflussgrößen anhand von zeitvarianten Modellzuständen abgebildet. Zur Kooperation der verschiedenen Modelle während der Trainings- und Prognosephase wurde eine geeignete Strategie definiert, die neben einem minimierten Fehler auch eine Reproduzierbarkeit der Ergebnisse ermöglicht. Hiermit sollen die oben genannten Anforderungen allgemeingültig erfüllt werden. Die theoretischen Grundlagen und ausgewählten Ansätze für die verwendeten Konzepte werden in § 4 näher beschrieben.

Zum Testen des Prognoseansatzes wurden analytische Modelle zur Simulation von Schadensverläufen hergeleitet, um eine möglichst breite Datenbasis zu schaffen und die breitbandige Anwendbarkeit des GP-UKF nachzuweisen. Hierbei bestand der Anspruch, durch eine einfache Parametrisierung das Auftreten von messbaren und nichtmessbaren Größen sowie deren Einfluss auf den Degradierungsverlauf vorzugeben und damit ausgehend von einem einzigen Modellierungsansatz unterschiedliche Kategorien von Schadensmodellen zu erstellen.

Um die Ergebnisse quantitativ bewerten zu können sowie Stärken und Schwächen des Ansatzes zu identifizieren, sind entsprechende Bewertungskriterien aufgestellt worden. Diese sollen alle relevanten Aspekte der Fehlerprognose messbar machen. Neben der Bewertung von Prognosekonzepten während der Entwicklungsphase kann mit den aufgestellten Kriterien auch eine Auswertung der Leistungsfähigkeit im laufenden Betrieb und zur Unterstützung von PBC-Konzepten eine kontinuierliche Messbarkeit der Prognosequalität ermöglicht werden.

Um die Verifikation des Prognosekonzeptes auch experimentell zu unterstützen, wurden mehrere Testläufe mit präparierten Wälzlagern eines Asynchronmotors für einen luftfahrtzertifizierten Lüfter durchgeführt. Das Ziel bei der Versuchsdurchführung war, einen möglichst realistischen Schadensverlauf mit reproduzierbaren Ergebnissen zu generieren. Durch die Reproduzierbarkeit soll eine Homogenität der verwendeten Trainingsdaten angestrebt werden, damit die Möglichkeiten zur kontinuierlichen Verbesserung der Prognosefähigkeiten mit einer Erweiterung der verfügbaren Datenbasis analysiert werden können.

Die synthetischen und experimentellen Daten wurden verwendet, um die Prognosefähigkeit anhand der ausgewählten Kriterien abschließend zu bewerten und mit einem ausgewählten Konzept, das den aktuellen Stand der Technik für hybride Fehlerprognose repräsentiert, zu vergleichen.

Zur gesamtheitlichen Darstellung des Prognoseansatzes sind abschließend die Leistungskennzahlen aus der Verifikation als Vorgabe für die entsprechenden Eingabeparameter des MMDL verwendet worden, um damit die Bewertung des operativen Potentials des Prognoseansatzes durchzuführen.

Die beschriebene Vorgehensweise und einzelnen Elemente der Implementierung und Verifikation des untersuchten Prognosekonzeptes sind nachfolgend in Abbildung 4 dargestellt:

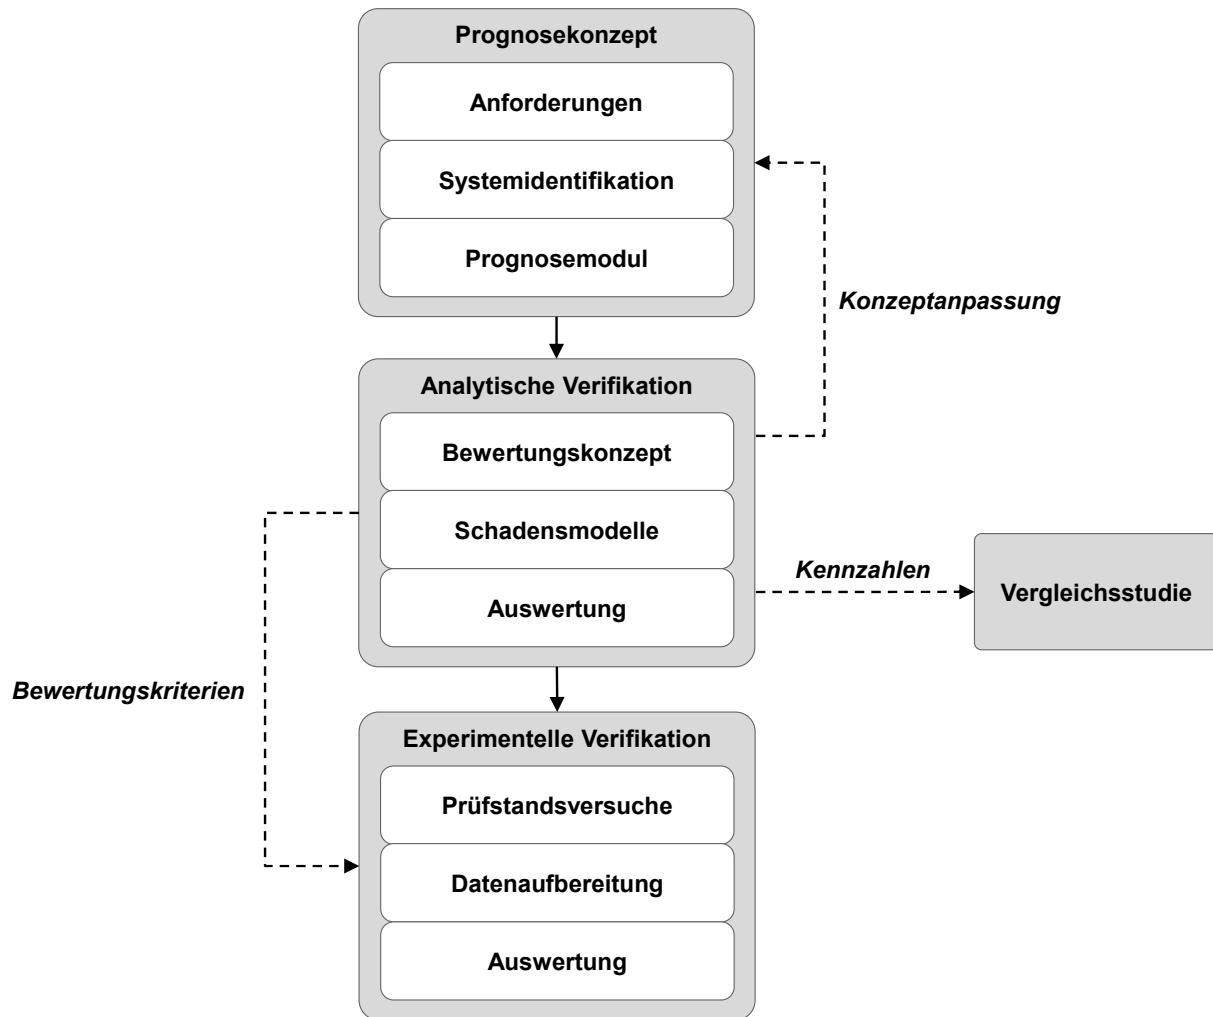


Abbildung 4: Vorgehensweise zur Implementierung und Verifikation des Prognosekonzeptes

1.3. Aufbau der Arbeit

Nachdem in § 1.1 die Motivation für die Inhalte dieser Arbeit diskutiert und in § 1.2 die Vorgehensweise zur Herleitung der Module und Auswertung der Ergebnisse beschrieben wird, gliedert sich die Arbeit weitergehend in zwei wesentliche Anteile:

- 1) Die Herleitung des Simulationskonzeptes zur Analyse des operativen Potentials von Luftfahrtssystemen im Allgemeinen und von Diagnose & Prognose im Speziellen.
- 2) Die Vorgehensweise für die Implementierung des hybriden Prognosekonzeptes und dessen Verifikation mittels synthetischen und experimentellen Messdaten sowie ein Vergleich mit einem etablierten Ansatz aus dem Bereich der hybriden Fehlerprognose.

Zunächst wird in § 2 für Bereiche, die für den Inhalt der Arbeit von Interesse sind, eine Zusammenstellung und Bewertung des aktuellen Stands der Technik mit Bezug zu vorhergehenden Arbeiten vorgenommen. Daraus abgeleitet ergibt sich die Zielsetzung der Arbeit für die genannten Anteile.

Die Grundlagen von Zustandsüberwachungssystemen und der Systemauslegung aus der Perspektive der Zuverlässigkeits- und Instandhaltungsanalyse werden für den ersten Teil in § 3.2 - § 3.6 näher

erläutert. Aus gängigen Vorgehensweisen in diesen Gebieten werden Modellierungsansätze abgeleitet, um die erreichbare Verfügbarkeit für eine gegebene Systemauslegung abzuschätzen.

Für die Integration der Fähigkeiten zur konventionellen und erweiterten Diagnose & Prognose werden in § 3.4 Konzepte aufgestellt und diskutiert, um einen funktionalen Zusammenhang zwischen der Qualität der Diagnose & Prognose und der erreichbaren Systemverfügbarkeit herzustellen. Die hierfür erforderlichen Zusammenhänge aus den Bereichen der Instandhaltung und Ersatzteilversorgung werden in § 3.5 und § 3.6 hergeleitet. Die gewählte Vorgehensweise zur Darstellung der ersten beiden statistischen Momente der Modellgrößen, bzw. der resultierenden Verteilungsformen von ausgewählten Modellausgabeparametern zur Unterstützung der PBC-Risikoanalyse, wird ebenfalls in den jeweiligen Abschnitten hergeleitet und diskutiert.

Die Validierung des MMDL mittels einer zertifizierten Simulationsumgebung wird in § 3.7 vorgenommen. Die beispielhafte Bewertung des operativen Potentials für das zur Validierung verwendete Szenario dient in § 3.8 als Bewertungsgrundlage, um die Motivation zur Entwicklung von Prognosefähigkeiten zu veranschaulichen.

Für die Herleitung des hybriden Prognosekonzeptes werden unterschiedliche Elemente aus den Bereichen der Systemidentifikation, der adaptiven Filterung und der Fehlerprognose miteinander kombiniert. Hierzu werden in § 4.2 und § 4.3 zunächst konzeptrelevante Anteile der Systemidentifikation mittels *Genetischer Programmierung* und der Auslegung von rekursiven bayesschen Schätzverfahren beschrieben. In § 4.4 werden ausgewählte Verfahren neu kombiniert um die modellbasierte Systemidentifikation zu ermöglichen. Die Implementierung relevanter Anteile zur Bewertung der Konsistenz von Schätzaufgaben und der Filterauslegung als integraler Bestandteil der modellbasierten Systemidentifikation wird anhand vereinfachter Szenarien nachgewiesen. Als Grundlage für die Erweiterung der modellbasierten Systemidentifikation, um auch hybride Filteransätze mit multiplen Modellen zu berücksichtigen, wird nach einer kurzen Einführung in die Thematik in § 4.5.1 durch § 4.5.2 ein allgemeingültiger Ansatz zur hybriden Systemidentifikation hergeleitet und die Implementierung anhand eines Beispiels nachgewiesen. Die Erweiterung zum hybriden Ansatz wird in § 4.5.3 vorgenommen. Mit diesen Vorarbeiten ist die Grundlage zur modellbasierten Systemidentifikation unter Berücksichtigung von multiplen Modellen geschaffen.

Die Erweiterung der modellbasierten Systemidentifikation, um auch als Prognosemodul genutzt werden zu können, wird in § 5 vorgenommen. Nach einer Diskussion der allgemeinen Grundlagen und Herausforderungen für Prognose in § 5.1 und § 5.2 wird die Vorgehensweise zur Implementierung und Optimierung der Prognosefähigkeit als eigenständige Funktion und integraler Bestandteil der Systemidentifikation in § 5.3 beschrieben und anhand allgemeingültiger Beispiele nachgewiesen.

Für die umfassende Bewertung der Prognoseleistungsfähigkeit werden in § 6.1 geeignete Kriterien aufgestellt und Testszenarien hergeleitet. Die Verifikation des hybriden Fehlerprognoseansatzes wird in § 6.2 und § 6.4 jeweils mit synthetischen und experimentellen Daten vorgenommen. Abschließend wird in § 6.5 noch ein Vergleich mit einem etablierten Ansatz aus dem Bereich der hybriden Fehlerprognose vorgenommen, um die Eigenschaften des hier untersuchten Prognoseansatzes auch objektiv beurteilen zu können. Die Verbindung zwischen den beiden Hauptanteilen der Arbeit wird in § 6.6 durch eine Analyse des operativen Potentials von Fehlerprognose für Luftfahrtsysteme unter Berücksichtigung der Leistungsfähigkeit des untersuchten Ansatzes vorgenommen.

Die Ergebnisse der Arbeit werden in § 7.1 zusammengefasst und abschließend in § 7.2 gesammelte Ideen und Möglichkeiten zur Optimierung und Weiterentwicklung beider Anteile diskutiert.

Eine anschauliche Übersicht des Aufbaus der Arbeit ist in Abbildung 5 gegeben:

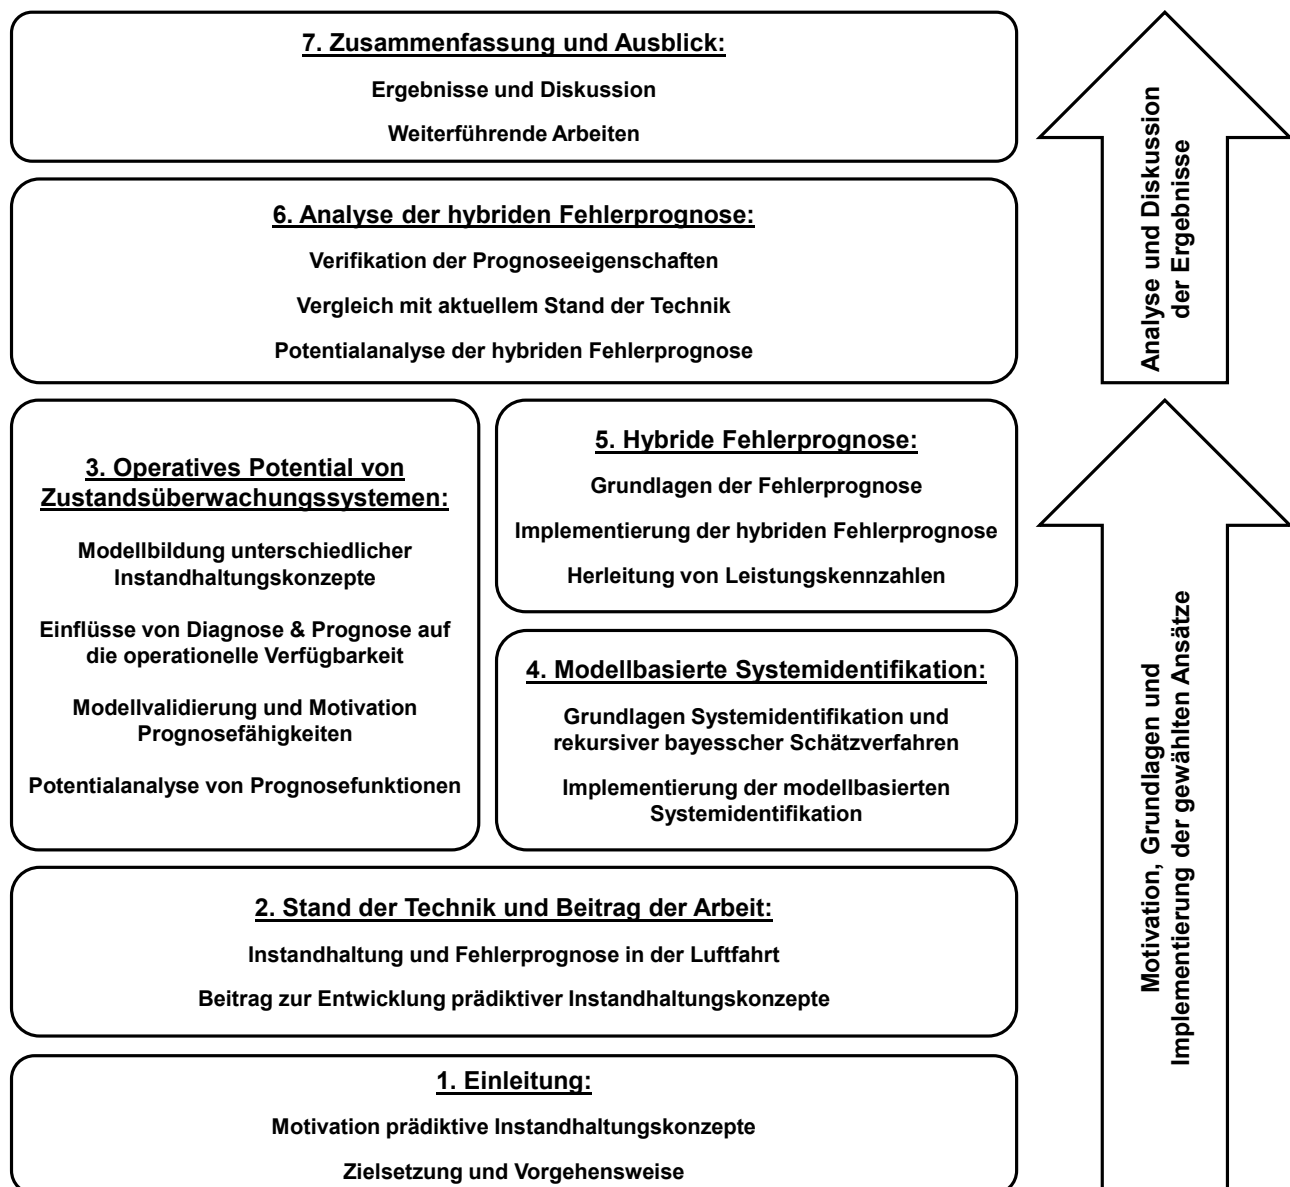


Abbildung 5: Inhaltlicher Aufbau der Arbeit

2. Stand der Technik und Beitrag der Arbeit

In diesem Abschnitt wird für die beiden Anteile „Diagnose & Prognose zur Unterstützung von zustandsbasierter Instandhaltung“ und „Fehlerprognose“ der aktuell bekannte Stand von luftfahrttechnischen Anwendungen und Technologievorhaben zusammengefasst sowie der Beitrag der Arbeit zur Entwicklung neuer Ansätze in diesen Bereichen erläutert.

2.1. Instandhaltungskonzepte für luftfahrttechnische Systeme

Logistische und instandsetzungsbedingte Aufgaben zur Gewährleistung der Betriebssicherheit und operationellen Verfügbarkeit bilden einen wesentlichen Anteil der Betriebskosten von Luftfahrtsystemen (s. Abbildung 6, exklusive Modifikationen [20], [21]). Für zivile Systeme fällt der prozentuale Anteil aufgrund der zusätzlichen Beiträge durch Steuern, Lohnkosten des Flugpersonals, zusätzlicher Serviceleistungen und Verbrauchsmittel geringer aus als für militärische:




Abbildung 6: Gesamten Betriebskostenanteile Luftfahrtsysteme: (a) Militärisch (Quelle: *RAND Corporation*, 2007), (b) Zivil (Quelle: *International Air Transport Association*, 2011)

Für Instandhaltungskonzepte wird zwischen den Strategien „*Run To Failure Maintenance*“ (RTFM), „*On Condition Maintenance*“ (OCM) und „*Condition Based Maintenance*“ (CBM) unterschieden:

Strategie	Merkmal
Run To Failure	Betrieb bis zum Auftreten eines Fehlers
On Condition	Festgelegte Inspektions- und Wiederinstandsetzungsmaßnahmen nach einer definierten Anzahl von Betriebsstunden, bzw. Lastzyklen
Condition Based	Dynamische Planung und Durchführung von Wiederinstandsetzungsmaßnahmen entsprechend dem beobachteten Systemzustand

Tabelle 3: Instandhaltungsstrategien

Die Maßnahmen der Instandhaltung zur Gewährleistung der operationellen Sicherheit und Betriebsfähigkeit werden in „*Corrective Maintenance*“, „*Preventive Maintenance*“ und „*Predictive Maintenance*“ aufgeteilt:

Maßnahme	Merkmal
Corrective Maintenance	Reaktive Maßnahme um eine geforderte Betriebsfähigkeit wieder herzustellen
Preventive Maintenance	Präventive Maßnahme zum Erhalt einer geforderten Betriebsfähigkeit zum sicheren Zeitpunkt bzw. als Resultat einer Inspektionsmaßnahme
Predictive Maintenance	Präventive Maßnahme zum Erhalt einer geforderten Betriebsfähigkeit zum möglichst optimalen Zeitpunkt durch Vorhersage einer Fehlfunktion oder nicht zulässigen Beeinträchtigung

Tabelle 4: Instandhaltungsmaßnahmen

Die verschiedenen Instandhaltungsstrategien unterscheiden sich in den Maßnahmen zur Gewährleistung der Betriebssicherheit und der ökonomischen Effizienz. Während eine *Run To Failure*-Strategie ausschließlich korrektive Maßnahmen ohne Inspektionsintervalle oder präventive Maßnahmen beinhaltet, ermöglicht ein *On Condition*-Ansatz eine Verbesserung der Sicherheit und Verfügbarkeit durch die Einbindung von fixen Inspektionsintervallen und präventiven Instandhaltungsmaßnahmen. Durch die Erweiterung auf *Condition Based* können in Abhängigkeit vom Zustand des operationellen Systems zusätzlich dynamische Wartungsintervalle berücksichtigt, bzw. fixe Inspektionsintervalle durch ein geeignetes Überwachungskonzept ersetzt werden. Daraus resultieren unterschiedliche Alternativen für ein Instandhaltungskonzept [22], [23]:

Strategie Maßnahme	Run To Failure	On Condition	Condition Based
Corrective Maintenance	Entspricht dem eigentlichen Konzept	Unkritische Fehlerfälle, die zu einem gefährlichen Betriebszustand, oder einem nennenswerten ökonomischen Schaden führen können	Unkritische Fehlerfälle, die weder zu einem gefährlichen Betriebszustand, noch zu einem nennenswerten ökonomischen Schaden führen können
Preventive Maintenance	Nicht enthalten	Fixe Intervalle oder Inspektionsmaßnahmen für Fehler mit Auswirkungen für die Sicherheit oder Wirtschaftlichkeit	Dynamische Intervalle für Fehler ohne Fähigkeit zur Vorhersage des Ausfallzeitpunktes und Auswirkungen für die Sicherheit oder Wirtschaftlichkeit
Predictive Maintenance	Nicht enthalten	Nicht enthalten	Dynamische Intervalle für Fehler mit Fähigkeit zur Vorhersage des Ausfallzeitpunktes und Auswirkungen für die Sicherheit oder Wirtschaftlichkeit

Tabelle 5: Instandhaltungsstrategien und mögliche Maßnahmen

Die *Run To Failure Maintenance*-Strategie soll hierbei nur als Teilmenge für unkritische Fehler erwähnt werden, da die Implementierung als ganzheitliches Konzept aufgrund von Zulassungsrichtlinien und ökonomischen Aspekten keine realisierbare Variante darstellt¹².

2.1.1. Zustandsbasierte Instandhaltung

Eine Umsetzung von *Condition Based Maintenance* würde zu einer hybriden Strategie mit fixen und dynamischen Intervallen führen, da im Betrieb aus technischen oder wirtschaftlichen Gründen nicht alle Zustände hinreichend genau überwacht, bzw. prognostiziert werden können. Durch eine idealisierte *On Condition*- oder *Condition Based*-Strategie sollte über den Lebenszyklus des Systems hinweg keine *Corrective Maintenance* notwendig sein. Dieser Idealzustand wird aus folgenden Gründen nicht erreicht [18], [13]:

- Für einige Komponenten lohnt sich der Aufwand für *Preventive Maintenance* oder *Predictive Maintenance* aufgrund rein wirtschaftlicher Aspekte und der Fehlerkritikalität nicht.
- Nicht alle Zustände sind während des Betriebes oder einer Inspektionsmaßnahme beobachtbar oder eindeutig quantifizierbar.
- Trotz der Entwicklung immer zuverlässigerer Methoden zur Zustandsüberwachung werden weiterhin Fehlalarmmeldungen generiert. Die darauf folgende Diagnosemaßnahme kann den Fehler nicht reproduzieren und generiert einen *No Fault Found* oder *Cannot Duplicate*.
- Für viele nicht sicherheitskritische Komponenten oder Funktionen kann der integrierte „*Build-In-Test*“ (BIT) bestimmte Fehler nicht einem dedizierten Gerät zuordnen und deshalb sind häufig mehrere Geräte einer Funktionsgruppe gleichzeitig zu überprüfen¹³.
- Ein nicht unerheblicher Anteil an Instandsetzungsmaßnahmen führt zu Sekundäreffekten, wobei die durchgeführten Arbeiten eine Beschädigung an funktionsfähigen Komponenten verursachen. Zu den Sekundäreffekten gehören auch direkte Auswirkungen von Gerätefehlern auf benachbarte oder in funktionaler Verbindung stehende Komponenten¹⁴.
- Trotz der hohen Anforderungen im Rahmen der Zulassung und Nutzung von Luftfahrtsystemen treten im Betrieb immer wieder systementwurfsbedingte (bei der Komponentenauslegung wurden nicht alle Systemeinflüsse berücksichtigt) oder durch Überlastung (bei der Komponentenauslegung wurden nur unzureichende Betriebsbedingungen berücksichtigt) verursachte Fehler auf.

¹² Zivile Richtlinien erfordern für CAT I eine maximale Fehlerrate von 10^{-9} (CAT II 10^{-7} , CAT III 10^{-5}), während für die Militärluftfahrt die Bestimmung des „*Residual Risks*“ durch den „*Risk Hazard Index*“ als Zulassung dient [24].

¹³ Für nicht sicherheitskritische Elemente wird üblicherweise eine BIT-Fehlerisoliationsrate von 100% auf drei, 95% auf zwei und 90% auf eine Komponente(n) gefordert, zulässige Abweichungen werden systemspezifisch evaluiert [25].

¹⁴ Sekundäreffekte können bei komplexen Systemen bis zu 10% der *Corrective Maintenance* verursachen.

Die Definition eines geeigneten Wartungskonzeptes erfolgt während der Entwicklungsphase und ist ein notwendiger Beitrag zur Erlangung der Luftfahrtzulassung. Das Wartungskonzept kann zwar während der Betriebsphase modifiziert werden, muss jedoch vor der Inbetriebnahme Maßnahmen definieren, um entwurfs- oder betriebsbedingte Risiken auf ein zulässiges Niveau zu reduzieren. Die militärische und zivile Luftfahrt unterscheiden sich hierbei zwar in den anzuwendenden Standards und Richtlinien, folgen im Prinzip jedoch einer ähnlichen Entscheidungslogik [22]:

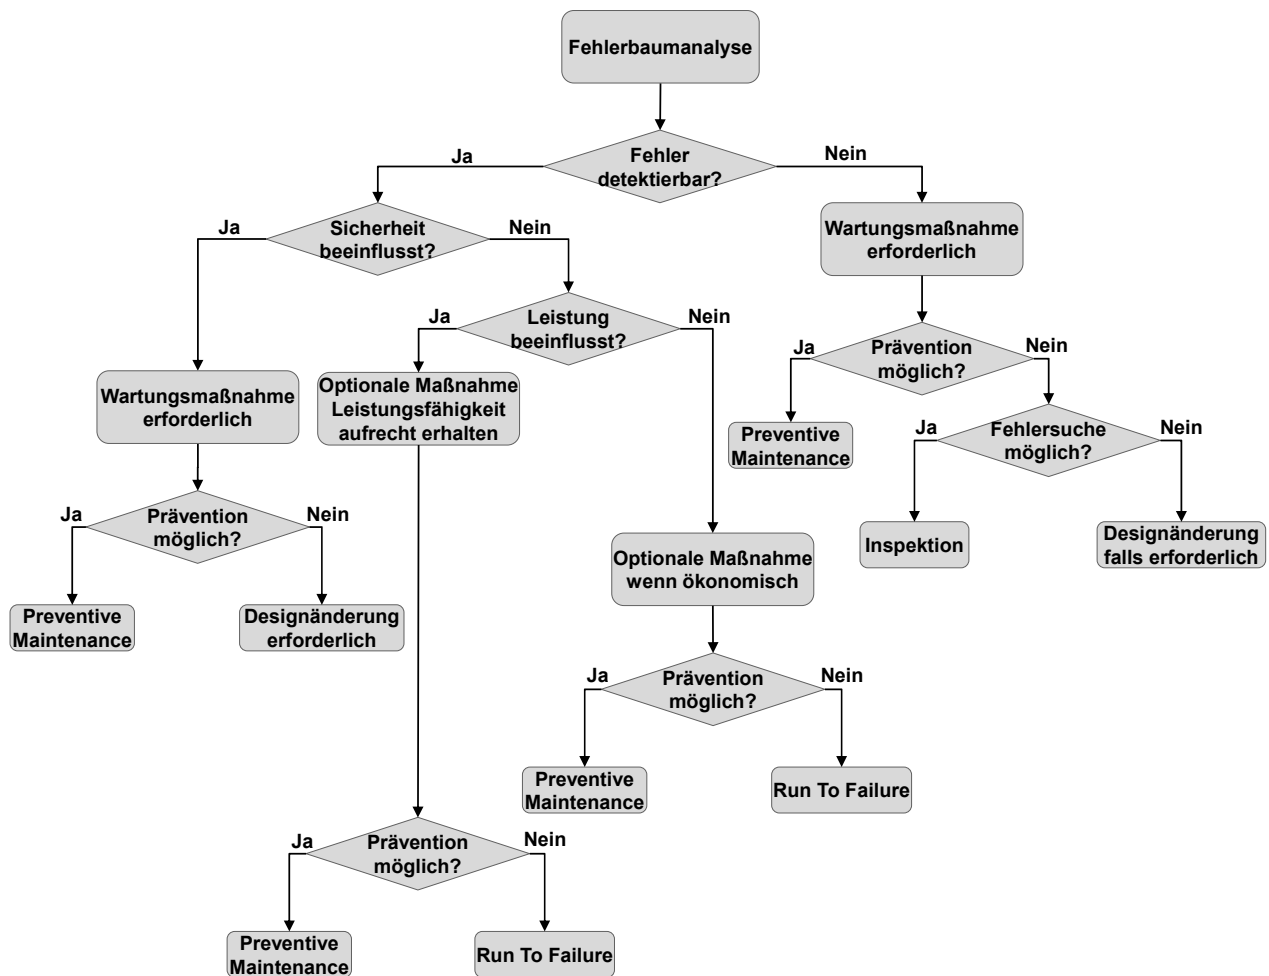


Abbildung 7: Entscheidungslogik für Planung und Zertifizierung von Instandhaltungsmaßnahmen

Wie aus der Entscheidungslogik ersichtlich, bieten die aktuellen Luftfahrtzulassungsprozesse nicht die Möglichkeit, *Condition Based Maintenance* vollumfänglich in die Entwicklung eines zertifizierbaren Wartungskonzeptes zu integrieren. Falls die Überwachungskonzepte es zulassen, kann eine *Preventive Maintenance* zwar durch die Quantifizierung einer Schadensgröße und die Abschätzung der verbleibenden Nutzungsdauer initialisiert werden, jedoch werden hier lediglich Grenzwerte definiert, ab denen die Wartungsmaßnahme umzusetzen ist, da eine weitere Zunahme der Schadensgröße oder Degradierung nicht zulässig ist obwohl die jeweilige Funktion noch erfüllt werden kann [26].

Erste Erfolge hinsichtlich der Zertifizierung von zustandsbasierten Wartungskonzepten in der Luftfahrt wurden mit den sogenannten „*Maintenance Credits*“ für Helikopter erzielt [27]¹⁵. Ein *Maintenance Credit* zielt darauf ab, während der Nutzungsphase Daten zu sammeln, die geeignet sind, ein bereits existierendes oder noch zu integrierendes Überwachungskonzept zu bestätigen. Wenn die Zuverlässigkeit des Konzeptes nach einer gewissen Nutzungsdauer des Systems erfolgreich nachgewiesen wurde, können bereits zertifizierte Instandhaltungsmaßnahmen, wie Inspektionen oder ein geplanter Komponentenaustausch, nachträglich durch eine Zustandsüberwachung ersetzt werden.

Die dynamische Bestimmung des optimalen Zeitpunktes zur Umsetzung der Wartungsmaßnahme anhand der Vorhersage des Schadensverlaufes und Harmonisierung mit anderen durchzuführenden Instandhaltungsaktivitäten ist jedoch bis heute nicht Teil des Zertifizierungsprozesses von Wartungskonzepten in der Luftfahrt [28].

2.1.2. Beitrag der Arbeit

Das MMDL soll einen Beitrag zur Implementierung und Zertifizierbarkeit von *Condition Based Maintenance* liefern, indem es für die Entwicklungsphase eine transparente Methode zur Nutzenanalyse inklusive Risikobewertung und Validierung von Auslegungsanforderungen für Diagnose- und Prognosesysteme zur Verfügung stellt. Durch die Implementierung als mathematisch geschlossene Lösung soll die Reproduzierbarkeit und damit auch die Allgemeingültigkeit der Aussagen gewährleistet werden. Damit wäre durch den Zusammenhang zwischen Kundenvorgaben für ausgewählte Leistungsmerkmale wie Verfügbarkeit oder Servicekapazitäten und den Anforderungen im Bereich Diagnose & Prognose eine Erweiterung der bisherigen Entwicklungsfähigkeiten von Zustandsüberwachungssystemen möglich. Neben der Validierung in der Definitionsphase, ist nach Abschluss der Entwicklung durch Vorgabe der erreichten Fähigkeiten, auch eine Verifikation der ursprünglichen Kundenanforderungen möglich, womit die Bewertung des operationellen Risikos vor Inbetriebnahme eines neuen Systems unterstützt werden kann.

2.2. Prognose der Lebensdauer für technische Systeme

Die Aufgabe von Prognosekonzepten für die Lebensdauer technischer Systeme besteht in der Bestimmung des Zeitpunktes, ab dem die spezifizierten Anforderungen einer Funktion nicht mehr erfüllt werden können. Hierbei kann das Versagenskriterium entweder eine unzulässige Abweichung von bestimmten Betriebseigenschaften oder der Verlust einer Funktionalität sein. Je nach Anwendungsfall kann die Lebensdauervorhersage zu Auslegungszwecken während der Entwicklungsphase

¹⁵ Die Arbeiten zur Zertifizierung von „*Maintenance Credits*“ für den S-92 Helikopter wurden von Smiths Aerospace und Sikorsky Aircraft Corporation durchgeführt und sind seit 2012 abgeschlossen. Bisher sind die vollständigen Ergebnisse noch nicht vorgestellt worden. Da die Finanzierung zum Großteil von der FAA bereitgestellt wurde ist eine Veröffentlichung jedoch gewährleistet.

oder zur Verbesserung der Verfügbarkeit und Sicherheit während der Nutzungsphase erforderlich sein. Zur Erfüllung dieser Aufgaben werden unterschiedliche Ansätze verfolgt. Grundlegend wird zwischen datenbasierten, modellbasierten und hybriden Methoden und den daraus hervorgehenden Ansätzen unterschieden [29], [30], [31], [32]:




Abbildung 8: Klassifikation von Prognoseansätzen

Während für die datenbasierten Methoden der wesentliche Aufwand in der Gewinnung und Aufbereitung von geeigneten Datensätzen liegt, erfordern die modellbasierten Verfahren die Entwicklung von detaillierten Modellen, um den realen Prozess möglichst repräsentativ abzubilden. Mit der Auswahl und Implementierung geeigneter Ansätze lässt sich bei hinreichender Qualität der verfügbaren Daten eine ebenso gute Prognosefähigkeit erzielen wie mit einer optimierten Modellierung. Hybride Konzepte bedienen sich in Abhängigkeit von der Verfügbarkeit geeigneter Daten und Modelle einer Kombination von datenbasierten und modellbasierten Anteilen. Die Auswahl der Vorgehensweise wird in der Regel durch die Qualität und Quantität der verfügbaren Daten, dem Verständnis des zu beschreibenden Problems zur Modellbildung und Datenanalyse sowie der verfügbaren Ressourcen zur Entwicklung und Nutzung der Prognosefähigkeiten bestimmt.

Eine Zusammenstellung der benötigten Informationen für die Entwicklung von rein erfahrungsbasierten Ansätzen bis zu detaillierten modellbasierten Verfahren ist in [33] gegeben (die Kategorie „*Erfahrungsbasiert*“ ist vergleichbar mit der Zuverlässigkeitsanalyse und gehört prinzipiell zur Klasse der datenbasierten Ansätze, wird hier jedoch als eigene Kategorie behandelt, da nach einer einmaligen Datenauswertung keine Algorithmik mehr zur Anwendung benötigt wird):

Information	Erfahrungsbasiert	Datenbasiert	Modellbasiert
Technisches Modell	Nicht erforderlich	Vorteilhaft	Erforderlich
Fehlerfallhistorie	Erforderlich	Nicht erforderlich	Vorteilhaft
Historie der Nutzung	Vorteilhaft	Erforderlich	Erforderlich
Aktuelle und geplante Nutzung	Vorteilhaft	Erforderlich	Erforderlich
Fehlerdiagnose	Nicht erforderlich	Erforderlich	Erforderlich
Historie der Wartung	Vorteilhaft	Nicht erforderlich	Vorteilhaft

Tabelle 6: Anforderungen zur Informationsbereitstellung für Prognoseansätze

Diese Zusammenfassung kann unter Berücksichtigung der Verfügbarkeit von Fähigkeiten und Informationen als Anhaltspunkt für die Auswahl eines geeigneten Ansatzes verwendet werden.

Für die in Abbildung 8 angegebene Klassifikation wird für einige datenbasierte Konzepte die Historie der Nutzungsbedingungen benötigt, weswegen die Verfügbarkeit der Informationen hier im Gegensatz zu der Darstellung in [33] als erforderlich definiert wird.

2.2.1. Datenbasierte Ansätze

Die Zuverlässigkeitsanalyse basiert auf der statistischen Auswertung von Fehlerfällen und gegebenenfalls der Korrelation mit aufgezeichneten Betriebszuständen, um bei vorgegebenem Nutzungsprofil eine Aussage über die erwartete Lebensdauer zu treffen. Hierbei fließt keine Information über den wirklichen Zustand mit in die Prognose ein. Mittels ausreichend konservativen Annahmen wird die Wahrscheinlichkeit für einen Fehlerfall zwar minimiert, jedoch das Lebensdauerpotential nicht optimal ausgenutzt, bzw. bei einer unzulässig großen Abweichung zwischen dem realen und theoretischen Nutzungsprofil ein Fehler während des Betriebes riskiert [34]. Eines der populärsten Verfahren aus diesem Bereich ist die Weibullanalyse [35]. Die auf Erfahrungswerten der Zuverlässigkeitsanalyse basierte Vorhersage von statischen Fehlerraten ist fester Bestandteil bei der Auslegung oder Modifikation von technischen Systemen, um erreichbare Kennwerte für die Zuverlässigkeit und Sicherheit abzuschätzen.

Das Trendmonitoring bedient sich der Zeitreihenanalyse, um einen beobachteten Teilverlauf bis zum Erreichen eines vordefinierten Grenzwertes zu extrapolieren. Bei geeigneter Wahl der Merkmale zur Trendanalyse können hinreichend genaue Aussagen über den wirklichen Zustand und möglichen Verlauf getroffen werden. Da das Trendmonitoring jedoch auf den jeweils aktuellen Verlauf angepasst werden muss, ist die Einbindung von Vorwissen nur bedingt möglich [36]. Das Trendmonitoring wird angewendet wenn keine ausreichende Kenntnis über den vorliegenden Schadensprozess besteht oder die verwendeten Parameter durch eine Vielzahl von Prozessen gebildet werden und keine umfassende Datenbasis zur Erstellung von Schadensmodellen vorhanden ist. Für die Zeitreihenanalyse kommen häufig Methoden aus dem Bereich der Autoregression zur Anwendung [37].

Bei der Lebensdaueranalyse wird anhand einer breiten Datenbasis ein direkter Zusammenhang zwischen dem aktuellen Zustand und der verbleibenden Nutzungsdauer hergestellt, ohne den wirklichen Verlauf der Schadensgröße zu berücksichtigen [38].

Die Prozessanalyse verwendet gesammelte Datensätze über den Schadensverlauf und die Nutzungsbedingungen zur Identifikation eines geeigneten Datenmodells. Das identifizierte Modell wird verwendet, um den Schadensverlauf als eine Funktion von Betriebsbedingungen und des beobachteten Zustandes bis zum Erreichen eines zulässigen Grenzwertes zu prognostizieren. Häufig verwen-

dete Methoden sind Neuronale Netze [39], Support Vector Machines [40] oder Fuzzy-Interferenz Systeme [41]. Der Gaußprozess ist eine neue und vielversprechende Methode zur Modellidentifikation durch parameterfreie Regression und damit ohne die Notwendigkeit von Vorkenntnissen über den Prognoseprozess [42]. Die Stärke der datenbasierten Prozessanalyse liegt in der Vielfältigkeit der Anwendungsgebiete und des nicht oder nur begrenzt benötigten Vorwissens über den zugrunde liegenden Prozess. Limitationen in der Anwendung resultieren hauptsächlich aus der auf den Trainingsdatensatz begrenzten Gültigkeit und fehlenden Fähigkeit zur Extrapolation aus diesem Gültigkeitsbereich heraus sowie Unkenntnis über die verwendeten Modelleigenschaften. Zusätzlich ist bei vielen Ansätzen nicht garantiert, dass die gefundene Lösung ein globales Optimum darstellt, wodurch einzelne Trainingsanteile mehr gewichtet werden als andere, was besonders bei der Anwendung für Prognose zu einer Divergenz des Ergebnisses führen kann [43].

2.2.2. Modellbasierte Ansätze

Modellbasierte Verfahren nutzen detailliertes Wissen über den Zusammenhang zwischen Sensorwerten, Auslegungsparametern und dem Degradierungsverlauf um funktionale oder physikalische Modelle aufzustellen. Durch die Identifikation von Parametern und Zuständen soll eine möglichst exakte Aussage über die überwachte Größe und alle mit dem Monitoring in Zusammenhang stehenden Unsicherheiten (Modellfehler, Messfehler und Bandbreite der Nutzungsbedingungen) getroffen werden. Um die jeweiligen Anteile optimal zu unterstützen werden unterschiedliche Modelle zur Identifikation (Prozessmodell) und Prognose (Schadensmodell) verwendet [44]. Die zu überwachende Zustandsgröße und alle erforderlichen Unsicherheiten werden mit dem Prozessmodell bestimmt. Für die Prognose wird das Schadensmodell genutzt, um den Degradierungsverlauf bis zum Erreichen eines vordefinierten Kriteriums zu prognostizieren. Weit verbreitet sind hier rekursive bayessche Schätzverfahren wie das ursprüngliche Kalman Filter für lineare Modelle (LKF) [45], Erweiterungen wie das „*Extended Kalman Filter*“ (EKF) [46] und „*Unscented Kalman Filter*“ (UKF) [47] für nichtlineare Modelle sowie Partikelfilter für Prozesse mit einer beliebigen Verteilungsform der Modellgrößen [48].

Um die lokale Gültigkeit der Modelle und damit die Qualität der Prognose zu verbessern, bzw. einen Ergebnisraum abzubilden, der durch ein einzelnes Modell nicht hinreichend genau beschrieben werden kann, sind *Multiple Model*-Ansätze entwickelt worden. Bei *Multiple Model*-Ansätzen werden mehrere Modelle parallel gerechnet und anhand einer geeigneten Kooperationsstrategie eine fusionierte Aussage über das zu erwartende Ergebnis getroffen [49].

Expertensysteme basieren auf detailliertem technischem Wissen über den Zusammenhang zwischen einem Schadensmerkmal und der verbleibenden Nutzungsdauer. Verwendet werden fixe Modellstrukturen, bzw. vordefinierte Entscheidungsbäume ohne die Möglichkeit zur Adaption an beobach-

tete Verläufe. Dadurch ist bei hinreichender Kenntnis über den zugrunde liegenden Prozess und die Nutzungsbedingungen zwar eine optimierte Prognose möglich, jedoch nicht genügend Robustheit gegenüber Modell- und Messungenauigkeiten gegeben [50].

2.2.3. Hybride Ansätze

Hybride Ansätze kombinieren die Stärken von daten- und modellbasierten Verfahren miteinander, um einige der konzeptspezifischen Limitationen zu umgehen, bzw. gewisse Ansätze überhaupt erst zu ermöglichen. Hierzu gehören Maßnahmen wie die Kompensation von Messungenauigkeiten und Parameterschätzung für datenbasierte Konzepte mittels adaptiven Filtern [51] oder die Bereitstellung von aufbereiteten Datenmodulen zur Ergänzung von Modellstrukturen für die ansonsten keine Modellierung möglich ist [52]. Auch für weitgehend bekannte Phänomene wie die Rissausbreitung in metallischen Bauteilen, für die etablierte Modellierungsansätze existieren, können durch die Einbindung von Datenmodulen zur Parameteridentifikation bessere Ergebnisse erzielt werden als durch einen rein modellbasierten Ansatz [53]. Andere hybride Ansätze nutzen mehrere Prognosealgorithmen parallel um für die Prognose ein fusioniertes Ergebnis zu bestimmen [54].

2.2.4. Anwendungsmerkmale

Alle genannten Ansätze für die Prognose der Lebensdauer technischer Systeme lassen sich unabhängig von der genutzten Methode in zwei Hauptkategorien einteilen:

- Lebensdauerberechnung
- Fehlerprognose

Für die Lebensdauerberechnung ist keine Ausprägung eines Schadensmerkmals erforderlich, um eine Aussage über die verbleibende Nutzungsdauer treffen zu können. Hierzu gehören im Wesentlichen Ansätze aus dem Bereich der Zuverlässigkeitsanalyse. Da keine Informationen über den aktuellen Zustand erforderlich sind, können diese Ansätze bereits während der Systemauslegung angewendet werden.

Die Fehlerprognose umfasst alle Ansätze, die ausgehend von einer Abweichung vom nominalen Betriebsverhalten mittels geeigneten Methoden eine Aussage über die verbleibende Nutzungsdauer bis zum Fehlerfall („*Remaining Useful Life*“ - RUL) treffen. Ein weiteres Unterscheidungsmerkmal stellt hierbei die Vorgehensweise zur Bestimmung der verbleibenden Nutzungsdauer dar:

- Prognose eines Ausfallzeitpunktes
- Prognose eines Schadensverlaufes

Zur zweiten Kategorie gehören hierbei nur solche Konzepte, die eine Prädiktion eines „*Condition Indicators*“ (CI – Indikator, der geeignet ist, den aktuellen Zustand der überwachten Funktion oder Komponente zu beschreiben) unter Berücksichtigung der zukünftigen Nutzungsbedingungen zulas-

sen. Dadurch wird eine an den beobachteten Verlauf angepasste Genauigkeit der Aussage ermöglicht. Hierzu zählen das Trendmonitoring, entsprechende datenbasierte Prozessanalysen sowie modellbasierte Ansätze, die Schadensmodelle oder speziell hierfür entwickelte Expertensysteme verwenden.

Die Fehlerprognose zur Prädiktion eines Schadensverlaufes wird üblicherweise durch eine vorgelagerte Überwachungsfunktion, die aus den Rohdaten der Sensoren im System einen geeigneten CI generiert, gesteuert. Für eine idealisierte Prognose entspricht der prognostizierte dem wahren Schadensverlauf und somit die vorhergesagte auch der verbleibenden Nutzungsdauer. Für reale Anwendungen wird die Prädiktion des Schadensverlaufes jedoch immer Abweichungen gegenüber dem wahren Verlauf und entsprechende Unsicherheiten bei der Vorhersage des Ausfallzeitpunktes aufweisen, wodurch die erreichbare Qualität der Prognose bestimmt wird (s. Abbildung 9):

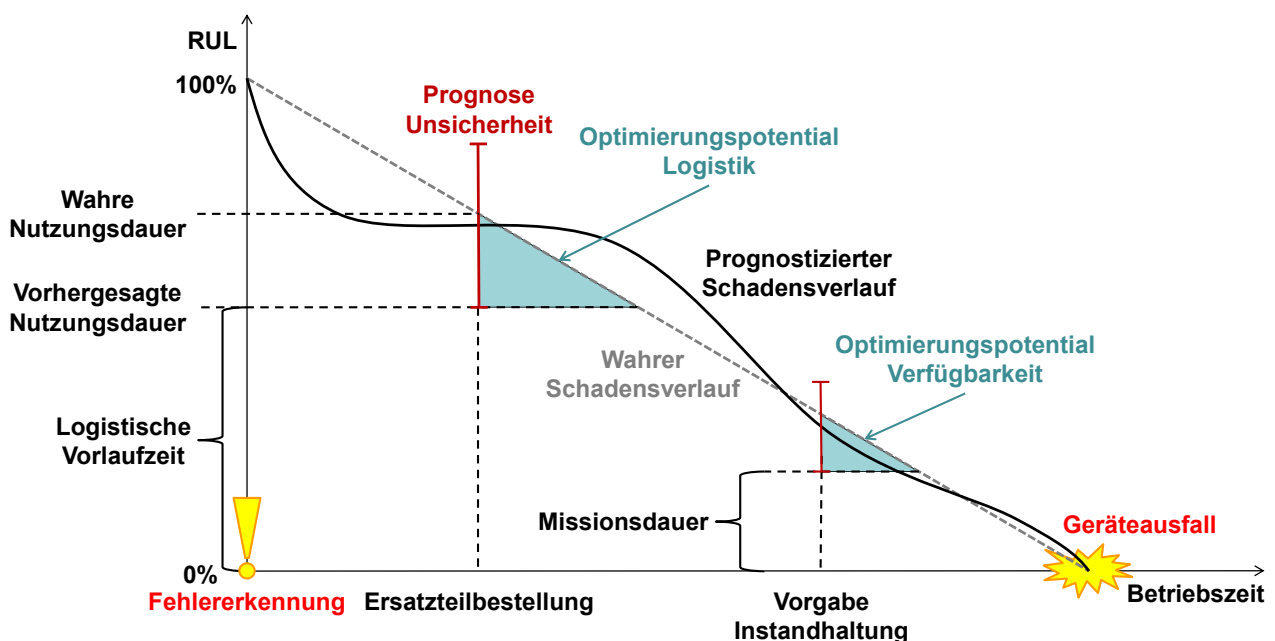


Abbildung 9: Fehlerprognose zur Unterstützung von zustandsbasierten Wartungskonzepten

Um den Nutzen der Prognose zu maximieren ist das wahre RUL mit möglichst hoher Genauigkeit (minimierte Abweichung zwischen vorhergesagtem und wahren Verlauf) und Präzision (minimierte Unsicherheiten der vorhergesagten Ausfallzeitpunkte) zu bestimmen. Die Qualität der Prognose steigt mit der Konvergenz des vorhergesagten Schadensverlaufes und der Unsicherheiten gegenüber dem wahren Schadensverlauf. Mittels der Konvergenzgeschwindigkeit und Stabilität der Prognose wird der Zeitraum (in Betriebsstunden, Lastzyklen, Schaltvorgängen etc.) definiert, über den hinweg eine zuverlässige Prognose möglich ist.

Bei der prädiktiven Instandhaltung spielen vor allem die Zeitpunkte der Ersatzteilbestellung und der Wartungsplanung eine wichtige Rolle. Je geringer hier die Abweichung zwischen dem prognostizierten und wahren RUL und die zugehörigen Unsicherheiten sind, desto optimierter kann der logis-

tische und wartungstechnische Prozess geplant werden. Wie in Abbildung 9 dargestellt, ist die Ersatzteilbestellung zu initialisieren wenn die vorhergesagte Nutzungsdauer der logistischen Vorlaufzeit entspricht und die Instandhaltung entsprechend wenn das vorhergesagte RUL nicht ausreicht, um eine weitere Mission abzuschließen (für eine vollständige Betrachtung müssten beide Anteile um die Reparaturzeiten erhöht werden). Um das Risiko einer Fehlplanung zu reduzieren wird hierfür jeweils eine untere Grenze der vorhergesagten Vertrauensbereiche gewählt. Die logistische Vorlaufzeit entspricht der Dauer, die von der Bestellung bis zum Eintreffen des Ersatzteils am Nutzungsort eingeplant werden muss. Hierbei können administrative, fertigungsbedingte, lieferbedingte und gegebenenfalls auch politische Einflüsse eine Rolle spielen. Für die Gewährleistung von vereinbarten Kosten- und Leistungsmerkmalen ist es daher wichtig, dass die logistische Vorlaufzeit bekannt ist und bei der Bevorratung und Nachbestellung von Ersatzteilen und Dienstleistungen entsprechend berücksichtigt wird. Durch eine Steigerung der Prognosequalität (verbleibende Nutzungsdauer nähert sich der logistischen Vorlaufzeit an) können Kosten für den Transport und die Lagerung von Ersatzteilen eingespart werden. Die Planung der Instandhaltung hat die Aufgabe, durch die Vorgabe des richtigen Zeitpunktes zum Austausch oder zur Reparatur, den Fehlerfall während des Betriebes zu vermeiden. Hier kann durch eine optimierte Prognose (verbleibende Nutzungsdauer nähert sich der Missionsdauer an) im Wesentlichen die Nutzungsdauer und damit die Verfügbarkeit erhöht werden. Entsprechend der jeweiligen Fehlerkritikalität sollte zur Reduzierung des Risikos für einen Fehlerfall im Betrieb die Vorhersage des Ausfallzeitpunktes immer mit einer entsprechenden Sicherheit gewählt werden.

2.2.5. Beitrag der Arbeit

Die Limitationen heutiger Prognoseverfahren resultieren häufig aus der problemspezifischen Gültigkeit der modellbasierten Verfahren und der begrenzten Verfügbarkeit von geeigneten Datensätzen für das Training datenbasierter Ansätze [54].

Das untersuchte Prognosekonzept zielt darauf ab, die Möglichkeiten zur modellbasierten Prognose zu erweitern, indem es die Herleitung von Schadensmodellen ohne vorheriges Modellwissen ermöglicht. Die Erweiterung der existierenden Ansätze zur Modellidentifikation mittels *Genetischer Programmierung* wird durch einen *Multiple Model*-Ansatz erzielt, wodurch die Vorteile dieser Verfahren genutzt werden sollen (s. auch § 4.5.1). Anstatt eine optimierte Lösung für einen spezifischen Anwendungsfall der Fehlerprognose zu finden, zielt das untersuchte Konzept darauf ab, eine möglichst breite Anwendbarkeit nachzuweisen. Durch die Implementierung des UKFs als Zustandsschätzer in die Prozesskette der Systemidentifikation wird die Berücksichtigung von nicht messbaren Modellgrößen ermöglicht. Die Prognosequalität ist durch die Implementierungsform und

Auswahl der Bewertungskriterien für die Systemidentifikation ein integraler Bestandteil der Lösungsfindung.

Bisherige hybride Ansätze von *Genetischer Programmierung* und Kalman Filtern konzentrierten sich auf die Bereinigung von Messunsicherheiten und die Optimierung von fixen Modellparametern [55], [56]. Prognoseansätze zur Verwendung von *Genetischer Programmierung* in Kombination mit einem EKF verwenden das Filter ausschließlich für die modellbasierte Prognose und zur Kompensation von Messungenauigkeiten, ohne den EKF während der Modellidentifikation zu nutzen [57]. Somit bietet der GP-UKF-Ansatz dieser Arbeit durch die integrierte Nutzung des UKFs und der Prognosefähigkeit als Bewertungskriterium für die Modellauswahl durch die *Genetische Programmierung* eine neue Methode zur modellbasierten Systemidentifikation von Degradierungsprozessen als Grundlage für eine automatisierte Entwicklung von Prognosefähigkeiten unter Berücksichtigung von nichtmessbaren Einflussgrößen und stochastischen Degradierungsprozessen.

3. Analyse von Zustandsüberwachungssystemen

In diesem Abschnitt wird ein Ansatz zur modellbasierten Analyse des Zusammenhangs zwischen Fähigkeiten zur Diagnose & Prognose für Luftfahrtsysteme und den systemspezifischen Leistungsmerkmalen wie Verfügbarkeit und Wartungsfreundlichkeit aufgestellt und mittels einer zertifizierten Simulationsumgebung validiert. Das validierte Modell wird genutzt, um aus der Nutzenanalyse von Zustandsüberwachungssystemen die Motivation zur Entwicklung von Fähigkeiten zur Fehlerprognose abzuleiten und anhand eines ausgewählten Beispiels auch quantitativ zu bewerten.

3.1. Operatives Potential von Zustandsüberwachungssystemen

Die resultierende Fehlerrate eines Systemverbundes wird durch die Ausfallraten der Einzelkomponenten bestimmt. Die Zuverlässigkeit bei der Erfüllung einer Funktion hängt zusätzlich von den Betriebsbedingungen ab und wie diese in der Entwicklungsphase berücksichtigt worden sind. Eine Instandhaltungsstrategie kann diese Eigenschaften nicht beeinflussen, jedoch können durch ein optimiertes Wartungskonzept die operationelle Verfügbarkeit erhöht und Betriebskosten zur Gewährleistung von erforderlichen Ressourcen reduziert werden [11].

Zur Allokierung von Wahrscheinlichkeiten und Kritikalitäten für jeden potentiellen Fehler und die jeweiligen Auswirkungen auf Systemebene werden standardisierte Verfahren wie die „*Failure Mode Effects and Criticality Analysis*“ und „*Common Mode Analysis*“ genutzt [58], [59]. Zielsetzung hierbei ist, eine Entscheidungsgrundlage zu schaffen, welche Fehler im Betrieb akzeptabel sind und für welche zur Vermeidung eine Instandhaltungsmaßnahme definiert werden muss. Falls keine geeignete Maßnahme identifiziert werden kann, ist je nach Kritikalität auch eine Änderung der System- oder Komponentenauslegung in Betracht zu ziehen. Die Entscheidungslogik hierbei entspricht der in Abbildung 7 dargestellten.

Zur Umsetzung eines optimierten Instandhaltungskonzeptes wird eine leistungsfähige Logistik und Zustandsüberwachung benötigt. Die Maßnahmen zur bedarfsgerechten Bereitstellung von Ressourcen stellen hierbei ein komplexes Feld dar, sind jedoch nicht im Fokus dieser Arbeit und sollen deshalb auch nicht detaillierter betrachtet werden.

Die Zielsetzung bei der Entwicklung eines Zustandsüberwachungssystems ist die Gewährleistung der Kenntnis über den aktuellen Zustand des operativen Systems, um die Planung und Durchführung von Instandhaltungsmaßnahmen zu unterstützen und kritische Betriebszustände zu vermeiden. Aufgrund der Komplexität der zugrunde liegenden Prozesse und Lösungsmöglichkeiten bei der Entwicklung eines Instandhaltungskonzeptes werden zur Unterstützung Simulationsumgebungen eingesetzt. Die Fähigkeit hierbei den Nutzen von Diagnose & Prognose zu bewerten und in die Entscheidungsfindung mit einfließen zu lassen ist jedoch nur unzureichend vorhanden [60].

Die Zielsetzung der hier vorgestellten Umgebung ist es, diese Fähigkeiten auszubauen und zusätzlich eine Risikoanalyse für PBC-Konzepte zu ermöglichen.

Hierbei besteht der Anspruch alle wesentlichen Elemente der Systemauslegung, Instandhaltung, Logistik und Zustandsüberwachung in der Modellbildung zu berücksichtigen. Lediglich die folgenden Anteile wurden vernachlässigt:

- Verfügbarkeit der Arbeitskräfte
- Limitationen zur parallelen Ausführbarkeit von Instandsetzungsmaßnahmen
- Kannibalisierung von Ersatzsystemen zur Ersatzteilgewinnung
- Planung und Organisation der Missionen und Instandsetzungsmaßnahmen

Die Simulation der Arbeitskräfteplanung würde das Ergebnis zu Gunsten der CBM-Strategie (und damit auch der Diagnose & Prognose) beeinflussen, da durch den prädiktiven Anteil vorhandene Risiken in der Verfügbarkeit von geeignetem Personal ähnlich wie bei Ersatzteilen gesteuert werden könnten. Die Abbildung von Arbeitsabläufen bei der parallelen Instandsetzung von mehreren Komponenten würde alle Instandsetzungsstrategien gleichermaßen betreffen und ebenfalls durch den prädiktiven Anteil und einer verbesserten Fehlerisolation als Teil der Zustandsüberwachung Auswirkungen zu Gunsten der CBM-Strategie haben. Die Kannibalisierung entspricht im Prinzip einer künstlich erhöhten Verfügbarkeit von Ersatzteilen bei reduzierter Verfügbarkeit von Ersatzsystemen und hat somit keine RTFM, OCM oder CBM spezifischen Auswirkungen. Die Optimierung eines Wartungs- und Missionsplanes basierend auf Vorgaben aus einem Zustandsüberwachungssystem kann als eigenständige Funktion betrachtet werden. Da diese Funktion jedoch nicht Teil des operativen Systems ist und um die Komplexität der Simulation zu reduzieren, wird idealisiert angenommen, dass die Vorgaben der Instandsetzung wie gefordert umgesetzt werden können. In einer realen Anwendung müsste diese Funktion zur Planung und Optimierung in die Kette der Bereitstellung und Auswertung von Informationen integriert werden.

Aufgrund dieser Zusammenhänge und weil die Zielsetzung dieser Arbeit die Bewertung des relativen Potentials von Zustandsüberwachungssystemen ist und nicht die Bestimmung der absoluten Leistungskennzahlen, können die getroffenen Vereinfachungen als vernachlässigbar und das Ergebnis zur Bewertung der CBM-Strategie als konservativ betrachtet werden.

Ein wesentlicher Unterschied zwischen den meisten bekannten Arbeiten in diesem Bereich und der hier vorgestellten Simulationsumgebung ist die mathematisch geschlossene Lösung des MMDL, womit sich reproduzierbare Ergebnisse ohne pseudo-empirische Simulationsreihen erzielen lassen. Hiermit soll die Nachweisführung vereinfacht und transparent gestaltet werden.

Nachfolgen werden der Modellierungsansatz für den deterministischen und stochastischen Anteil sowie alle funktionalen Elemente des MMDL näher beschrieben.

3.2. Modellierungsansatz für das deterministische Modell

Der Modellierungsansatz folgt einer hierarchischen Komposition von Modellelementen zur Abbildung des Systementwurfs und Betreiberkonzeptes, der Einflüsse auf die LCC relevanten Elemente der Wartung, Bodenstandzeiten und Logistik sowie der daraus resultierenden operationellen Leistungsfähigkeit:

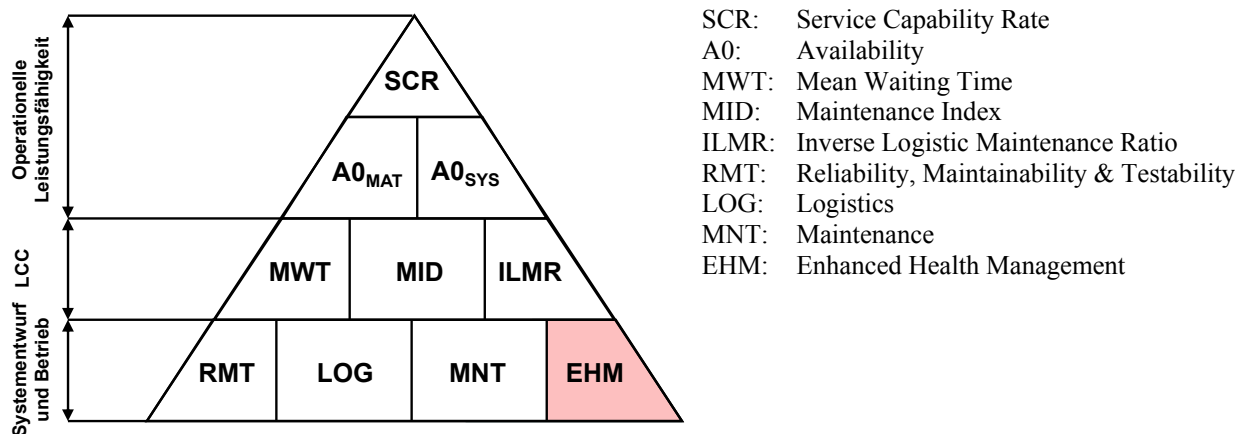


Abbildung 10: Hierarchische Modellstruktur für die Potentialanalyse von Diagnose & Prognose

Der zur Bewertung der operationellen Leistungsfähigkeit verwendete Parameter ist die „Service Capability Rate“ (SCR). Durch diese Größe wird analog zur Systemverfügbarkeit die Wahrscheinlichkeit zur erfolgreichen Erfüllung einer Aufgabe in einem vordefinierten Szenario beschrieben. Sie wird direkt durch die Verfügbarkeit des operativen Systems und der benötigten Missionsausrüstung bestimmt. Die zugrundeliegende Annahme ist, dass zur Erfüllung einer Aufgabe sowohl das operative System als auch die aufgabenspezifische Ausrüstung benötigt werden. Je nach Systemtyp und Szenario kann die Aufgabe beliebig definiert sein, wie z.B. der Transport von Gütern und Passagieren oder die Bereitstellung von Aufklärungsleistung (gesamtes Flugsystem), Flugleistung (Triebwerk) oder Datentransfer (Informationssystem). Je nach Definition des Systemtyps und der Systemgrenzen können die Anforderungen zur Erfüllung der Aufgabe von funktionalen Anforderungen einzelner Komponenten bis zur Abbildung von gesamtheitlichen Betreiberkonzepten variieren.

Der eigentliche Systementwurf wird durch den Anteil „Reliability, Maintainability & Testability“ (RMT) beschrieben. Hier wird die jeweilige Zuverlässigkeit und Fehlerkritikalität aller Komponenten definiert („Reliability“). Die Wartungsfreundlichkeit („Maintainability“) gibt an, welche Anforderungen der Austausch von fehlerhaften Komponenten in Form von benötigtem Personal und Reparaturzeiten aufstellt. Die Fähigkeit zur Fehlerdiagnose („Testability“, inklusive Fehlererkennung und Fehlerisolation) beschreibt die Wahrscheinlichkeit zur korrekten Isolation eines Fehlers und den Anteil der Fehlalarmmeldungen, die durch den irrtümlichen Austausch einer funktionsfähigen Komponente zu einem *Cannot Duplicate* oder *No Fault Found* führen.

Die Vorgehensweise bei der Versorgung mit Ersatzteilen wird durch den Logistikanteil (LOG) modelliert. Hier wird zwischen fixen und bedarfsorientierten Intervallen unterschieden. Die Vorgaben aus diesem Element werden benötigt, um die Auswirkungen des Ersatzteilbestandes als Funktion der Ausfallraten auf die Systemverfügbarkeit abzubilden.

Die Instandhaltungsstrategie (MNT) beschreibt komponentenspezifisch und ganzheitlich welche Fehler durch welche Maßnahmen gehandhabt werden. Die Entscheidungsmöglichkeiten richten sich hierbei nach den Definitionen in Tabelle 5.

Die standardisierte Fehlererkennung ist durch den RMT-Anteil abgedeckt. Hierbei werden jedoch lediglich die BITs zur Erkennung von bereits aufgetretenen Fehlern mit nicht perfekter Fehlerisolation berücksichtigt. Um zusätzlich auch die Fähigkeit zur Zustandsüberwachung (Bewertung der Schadensgröße vor Auftreten eines Fehlers und Isolation auf Komponentenebene) und Fehlerprognose betrachten zu können, ist der Anteil „*Enhanced Health Management*“ (EHM) eingeführt worden. Hier werden die Leistungsparameter zur Quantifizierung der Schadensgröße und Vermeidung von Fehlalarmen (Diagnose) sowie der Genauigkeit und Präzision zur Vorhersage des Ausfallzeitpunktes (Prognose) genutzt, um den Einfluss auf den Ressourcenbedarf und die Systemverfügbarkeit abzubilden und die Grundlage zur Bewertung von Diagnose & Prognose zu schaffen. Die Fähigkeit zur Diagnose ist hierbei eine notwendige Voraussetzung für Prognose.

Die Elemente der nächsthöheren Kategorie (LCC) werden direkt aus den Basiselementen RMT, LOG, MNT und EHM abgeleitet. Die „*Mean Waiting Time*“ (MWT) beschreibt die durchschnittliche Wartezeit bevor das System nach einer Instandsetzung wieder betriebsfähig ist (ohne den Anteil der Reparaturzeiten) und hat in Abhängigkeit vom Logistikkonzept einen maßgeblichen Einfluss auf die operationelle Verfügbarkeit. Der Einfluss der Wartungsarbeiten wird durch den „*Maintenance Index*“ (MID) in Form von benötigten Mannstunden pro Betriebsstunde ausgedrückt. Das „*Inverse Logistic Maintenance Ratio*“ (ILMR) bildet das Verhältnis zwischen der Anzahl der Wartungsmaßnahmen und den akkumulierten Betriebsstunden und ist somit auch ein Maß für die Art und Anzahl der benötigten Ersatzteile zur Aufrechterhaltung der Systemverfügbarkeit. Im Gegensatz zur üblichen Verwendung des Parameters „*Logistic Maintenance Ratio*“ für ungeplante Fehlerfälle im Betrieb, werden hier zur Reduzierung der benötigten Modellparameter alle Instandhaltungsmaßnahmen zusammengefasst.

Bei der Entwicklung des MMDL bestand der Anspruch, ein beliebig komplexes System mit allen relevanten Fehlerquellen und Interaktionen während des Betriebes auch für wahlweise hybride Instandhaltungsstrategien abzubilden.

Die hierfür entworfene funktionale Architektur ist in Abbildung 11 gegeben:

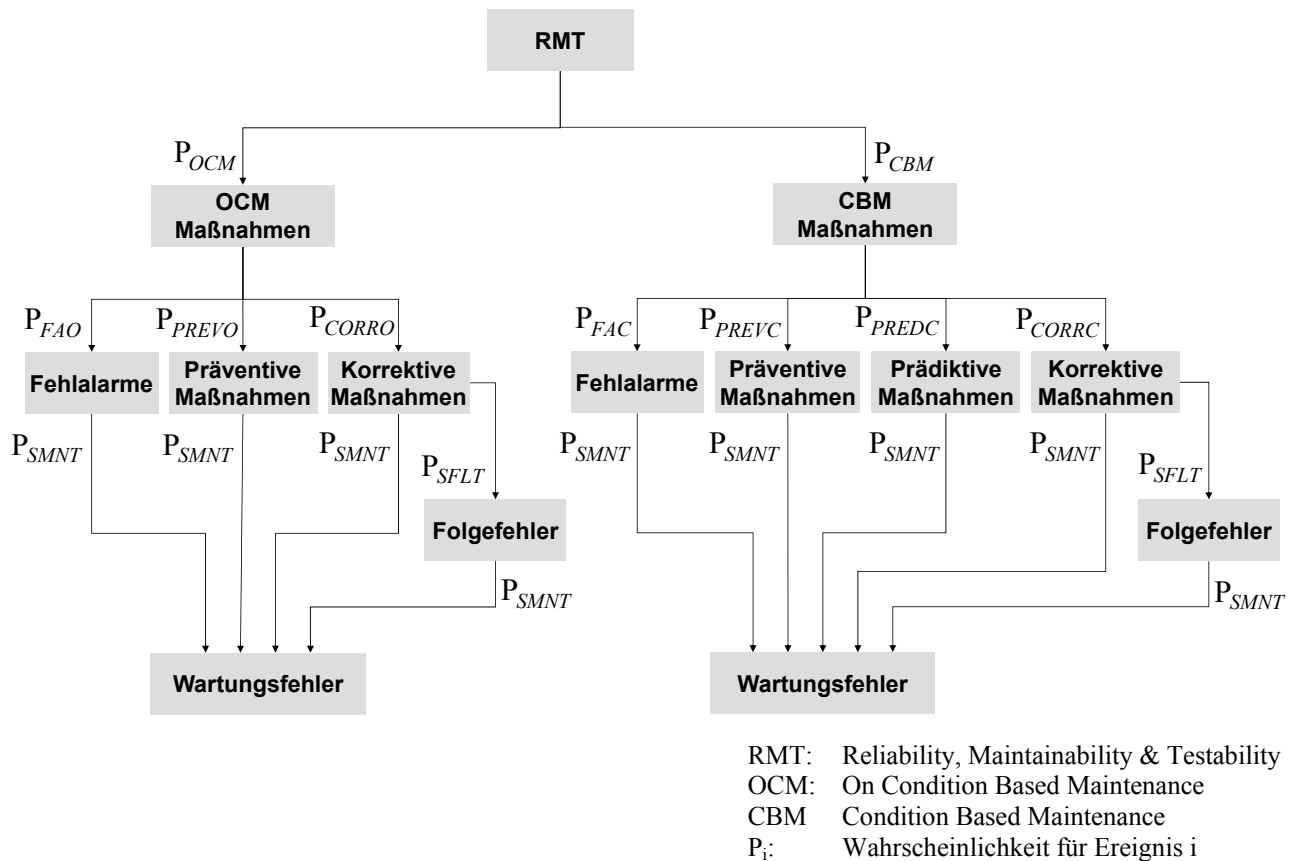


Abbildung 11: Funktionale Architektur der Fehlersimulation

Die dargestellte Architektur berechnet für ein bekanntes Systemdesign und Wartungskonzept die resultierenden Raten für geplante und ungeplante Maßnahmen. Die einzelnen Fehler werden entsprechend den Gewichtungsfaktoren P_i einer Instandhaltungskategorie zugeordnet. Hierbei kann ein bestimmter Fehler immer nur einer bestimmten Kategorie angehören. Grundsätzlich wird zwischen OCM und CBM unterschieden. Die RTFM-Strategie wurde nicht explizit berücksichtigt, entspricht jedoch dem korrektiven Anteil der OCM Maßnahmen. Beide dargestellten Instandhaltungsstrategien besitzen einen Anteil präventiver und korrektiver Maßnahmen sowie zusätzliche Fehlalarme, die durch die Leistungsfähigkeit des jeweiligen Überwachungskonzeptes definiert sind. Der CBM Strang ermöglicht zusätzlich prädiktive Maßnahmen, die eine Diagnose- und Prognosefähigkeit voraussetzen. Alle nicht durch präventive oder prädiktive Maßnahmen verhinderten Fehler verursachen mit einer vordefinierten Wahrscheinlichkeit P_{SFLT} Folgefehler. Außerdem besteht bei jeder Instandsetzung eine Wahrscheinlichkeit P_{SMNT} zusätzliche wartungsinduzierte Fehler zu verursachen.

Außer der Fähigkeit zur Fehlerprognose besteht der Unterschied zwischen dem OCM und CBM Anteil darin, dass die präventiven Maßnahmen im OCM Strang nach fixen Intervallvorgaben erfolgen, während CBM eine präventive Maßnahme abhängig vom Zustand der überwachten Komponente initialisiert („Condition-Based“). Des Weiteren wird für die korrektiven Anteile von CBM eine perfekte Fehlerisolation angenommen, während für OCM nicht alle Fehler eindeutig einer

Quelle zugeordnet werden können. Somit erfordert jeder Fehlertyp der Kategorie CBM auch eine entsprechende Zustandsüberwachung. Alle korrektiven Maßnahmen und Fehlalarme sowie der präventive Anteil des CBM-Strangs werden als ungeplante Instandhaltung modelliert und beeinflussen in Abhängigkeit von logistischen Wartezeiten und der Ersatzteilbevorratung über die Reparaturzeiten hinaus zusätzlich die Systemverfügbarkeit.

Um eine Aussage über die mittlere Systemzuverlässigkeit zu erhalten werden die Ergebnisse aller Kategorien zusammengefasst. Mit der durch die Fehlerraten und Fähigkeit zur Fehlerisolation gewichteten mittleren Reparaturzeit (s. § 3.4.1 und § 3.5.2) ist aus der Beziehung (1.1) ein Ausdruck hergeleitet worden, der aus den o.g. LCC-Blöcken eine Bestimmung der operationellen Verfügbarkeit ermöglicht:

$$A_0 = \frac{1}{1 + MID + ILMR \cdot MWT} \cdot 100 \quad (5.1)$$

wobei:

$$MID = \lambda \cdot MTTR$$

Um auch zusätzliche Einflüsse, wie eine Optimierung der Turnaroundzeiten durch automatisierte Systemchecks mittels EHM und unterschiedliche Auslastungsraten über einen bestimmten Zeitraum („Utilization Rate“ - UR), zu berücksichtigen ist (5.1) entsprechend erweitert worden:

$$A_0 = \frac{1}{1 + \left(\lambda \cdot (T_R + T_W) + ((1 - \theta_{CBM}) \cdot (1 - \theta_M) + \theta_M) \cdot \frac{T_T}{T_M} \right) \cdot UR} \cdot 100 \quad (5.2)$$

Das MMDL ermöglicht die Simulation von mehreren operativen Systemen parallel, um bei Ausfall eines Systems die Aufgabe mit einem Ersatzsystem weiter zu unterstützen. Somit entspricht die resultierende SCR einer ODER/UND-Verknüpfung der operationellen Verfügbarkeit von Einzelsystemen:

$$SCR = \left(\prod_{i=1}^N \left(1 - \left(1 - \frac{A_{0i}}{100} \right)^{n_i+1} \right) \right) \cdot 100 \quad (5.3)$$

mit:

N = Anzahl der benötigten Systeme um eine Aufgabe zu erfüllen

n = Anzahl der verfügbaren Ersatzsysteme

Zusätzliche Aspekte wie Anflugzeiten von Wartungspunkten oder Transferflüge etc. sind in diesem Modell nicht berücksichtigt, könnten jedoch durch eine Erhöhung der Wartezeit oder einer entsprechenden Erweiterung von (5.3) abgebildet werden.

3.3. Modellierungsansatz für das stochastische Modell

Für die Simulation von Unsicherheiten werden durch eine Erweiterung des deterministischen Modellansatzes neben den Erwartungswerten der Modellparameter auch deren Varianzen hergeleitet.

Um die Flexibilität bei der Bestimmung von A_0 und SCR maximal zu halten, sind hierfür zweiparametrische Weibullverteilungen ohne Vorgabe des Formparameters verwendet worden¹⁶. Die Fehlerraten des Systems werden über die Nutzungsdauer als konstant angenommen, womit sich für die Ausfallzeitpunkte eine Exponentialverteilung ergibt. Zur Abschätzung der Unsicherheiten bei den gemittelten Fehlerraten wird in [61] ein Verfahren beschrieben, das von einer logarithmischen Normalverteilung ausgeht. Die Parameter der Verteilung μ_κ, ν_κ für die Fehlerraten λ werden mittels der 95% Perzentile¹⁷ der Standardnormalverteilung¹⁸ u_α und eines Fehlerfaktors κ hergeleitet:

$$\nu_\kappa = \frac{1}{u_\alpha} \cdot \log(\kappa) \quad (5.4)$$

$$\mu_\kappa = \log(E[\lambda]) - \frac{\nu_\kappa^2}{2} \quad (5.5)$$

Durch diese Vorgehensweise wird sichergestellt, dass die Fehlerraten mit 90% Wahrscheinlichkeit in einem durch den Fehlerfaktor κ definierten Wertebereich Λ um den Zentralwert $\lambda_{0,5}$ liegen:

$$P\left(\frac{\lambda_{0,5}}{\kappa} < \Lambda < \kappa \cdot \lambda_{0,5}\right) = 1 - 2 \cdot \alpha \quad (5.6)$$

mit:

$\alpha = 0,05$ als Faktor für 95% Perzentile der Standardnormalverteilung

Die Varianz für die resultierende Verteilung bestimmt sich nach (5.7):

$$\sigma^2_\lambda = \exp\left(2 \cdot \mu_\kappa + \nu_\kappa^2\right) \cdot \left(\exp(\nu_\kappa^2) - 1\right) \quad (5.7)$$

Für die Modellierung von logistischen Wartezeiten und Reparaturzeiten wurde ausgehend von Literaturstudien analog die logarithmische Normalverteilung ausgewählt [62], [63]. Fehlalarmraten und nicht perfekte Diagnose & Prognose werden ebenfalls durch die logarithmische Normalverteilung abgebildet, da durch diesen Verteilungstyp stets Werte größer Null angenommen werden, kleine Werte (verhältnismäßig geringe Fehler als Maßstab für die geforderte Qualität der Diagnose & Prognose) mit einer hohen Wahrscheinlichkeit um den Modalwert (Auslegungskriterium der Zustandsüberwachung um zertifizierbar zu sein) verteilt liegen aber auch große Abweichungen (einzelne Ausreißer, insbesondere für Prognose) zugelassen werden [63]. Die Parameter der Verteilungen sind mittels der ersten beiden statistischen Momente (Erwartungswert und Varianz) entweder direkt oder durch Maximum-Likelihood Schätzer bestimmt worden.

¹⁶ Die Weibullverteilung erlaubt in Abhängigkeit des Formparameters eine Abbildung von verschiedenen Verteilungstypen wie z.B. Exponential-, Normal- und Rayleighverteilungen [64].

¹⁷ Üblicherweise wird α mit 0,05 gewählt, damit die Wahrscheinlichkeit für die Einhaltung des Wertebereiches bei 90% liegt, jede andere Parametrisierung zur Abbildung einer entsprechenden Unsicherheit ist jedoch ebenso möglich.

¹⁸ Die Vertrauensbereiche der Standardnormalverteilung können hierfür genutzt werden, da die Standardabweichung bei einer Parallelverschiebung zum Erwartungswert der Fehlerrate unverändert bleibt.

Die durch (5.4)-(5.7) beschriebene Vorgehensweise wurde für alle Parameter mit logarithmischer Normalverteilung genutzt. Alle verwendeten Verteilungstypen der stochastischen Anteile des MMDL sowie die Annahmen zur Herleitung der Ausdrücke für die Erwartungswerte und Varianzen der jeweiligen Modellgrößen sind in Anhang B gegeben. Die wesentliche Annahme bei der Modellbildung ist, dass alle primären Fehler (korrektiv, präventiv, prädiktiv und Fehlalarme) stochastisch unabhängige Ereignisse darstellen. Diese Annahme wird auch allgemein bei Systemauslegungen genutzt, um die Systemzuverlässigkeit abzuschätzen. Somit können die Einzelvarianzen der Ausfallraten zu einer resultierenden Varianz auf Systemebene aufsummiert werden. Die stochastische Abhängigkeit der sekundären Fehler von den anderen Fehlerklassen wird aufgrund der Korrelation gesondert betrachtet:

$$\sigma_{j|i}^2 = P_{j|i}^2 \cdot \sigma_i^2 \quad (5.8)$$

mit:

$P_{j|i}$ = Wahrscheinlichkeit für Sekundäreffekt j ausgehend von Fehlerkategorie i

Mit Hilfe der Definition des Korrelationskoeffizienten und unter der Annahme eines perfekten linearen Zusammenhangs zwischen primären und sekundären Fehlern (ein relativer Anstieg in der Primärfehlerrate würde den gleichen relativen Anstieg in der Sekundärfehlerrate bewirken), lässt sich unter Verwendung von (5.8) ein Ausdruck für die Kovarianz der Sekundäreffekte herleiten:

$$\text{cov}_{j|i} = \rho_{j|i} \cdot \sqrt{\sigma_i^2} \cdot \sqrt{\sigma_{j|i}^2} = \sigma_i^2 \cdot P_{j|i} \quad (5.9)$$

mit:

ρ = Korrelationskoeffizient (≈ 1 für perfekten linearen Zusammenhang)

Durch die darauf aufbauende Herleitung der Verteilungen für A_0 und SCR lässt sich auch die Wahrscheinlichkeit für das Erreichen eines vorgegebenen Wertes bestimmen:

$$P_x = \int_{-\infty}^{x_D} f(x) dx \quad (5.10)$$

mit:

x = PBC Parameter (entspricht hier A_0 oder SCR)

x_D = Geforderter Wert für PBC Parameter

$f(x)$ = Wahrscheinlichkeitsdichtefunktion des PBC Parameters

Damit ergibt sich das Risiko für die PBC-Analyse des betrachteten Parameters zu:

$$R_x = (1 - P_x) \cdot 100 \quad (5.11)$$

Die Implementierung der getroffenen Annahmen wird in den folgenden Kapiteln näher beschrieben und diskutiert.

3.4. Zustandsüberwachung

Das Überwachungskonzept wird durch die beiden Anteile Testability (BITs) und EHM abgebildet. Alle Fehler, die ausschließlich durch ein BIT überwacht werden, gehören zum OCM-Strang und besitzen keine Prognosefähigkeiten. Die Fehlertypen, für die ein EHM-Konzept definiert ist, gehören zur CBM-Strategie. Eine Auflistung der Kategorien und zugehörigen Eigenschaften für die Modellierung der Zustandsüberwachung ist in Tabelle 7 gegeben:

Maßnahme	Eigenschaften
OCM Präventiv	Überwachung durch BITs mit bedingter Vermeidung von Fehlern
OCM Korrektiv	Überwachung durch BITs ohne Vermeidung von Fehlern
CBM Prädiktiv	Überwachung durch EHM mit Prognosefähigkeiten
CBM Präventiv	Überwachung durch EHM mit bedingter Vermeidung von Fehlern
CBM Korrektiv	Überwachung durch EHM ohne Vermeidung von Fehlern

Tabelle 7: Kategorien der MMDL Zustandsüberwachung

Die Anteile Diagnose & Prognose werden entsprechend dieser getroffenen Unterscheidungen für die Modellierung berücksichtigt.

3.4.1. Fehlerdiagnose

Heutige Diagnosesysteme für luftfahrttechnische Anwendungen basieren auf einer Kombination von BITs und Zustandsüberwachungssystemen [65]. Hierfür werden während der Entwicklungsphase dedizierte Instrumentierungen und Konzepte berücksichtigt, die eine zertifizierbare Grundlage für die BITs liefern. Ein BIT wird je nach Anwendungsfall als P-BIT („*Power-Up BIT*“ während des Komponenten- oder Systemstarts), C-BIT („*Continuous BIT*“ während des Betriebes) oder I-BIT („*Initiated BIT*“ koordiniert initialisiert während bestimmter Betriebsphasen) ausgeführt. Zielsetzung ist jeweils die Durchführung einer vordefinierten Testprozedur und ein Abgleich des Verhaltens mit spezifizierten Grenzwerten, um zu entscheiden, ob die jeweilige Funktion noch hinreichend erfüllt werden kann. Durch festgelegte Testprozeduren und während der Komponenten- und Systemqualifikation definierter und nachgewiesener Grenzwerte für unzulässige Abweichungen vom geforderten Verhalten, ist die Wiederholbarkeit und damit auch Zuverlässigkeit des BITs gewährleistet.

Des Weiteren wird für ausgewählte Parameter und Zustände eine intervallbasierte oder kontinuierliche Überwachung und Bewertung des verbleibenden Spielraums zu vordefinierten Grenzwerten vorgesehen. Hierzu zählen z.B. das „*Usage Monitoring*“ für Strukturbauteile [66] oder das „*Engine Trend Monitoring*“ für Triebwerke [67].

Der Unterschied zwischen diesen beiden Vorgehensweisen liegt in der konstanten Zuverlässigkeit des BITs zwischen zwei Zuständen unterscheiden zu können und der Fähigkeit der kontinuierlichen Zustandsüberwachung eine Veränderung im Betriebsverhalten bereits vor dem Auftreten eines Fehlers zu bewerten. Zur Illustration sind in Abbildung 12 die Unterschiede zwischen einer kontinuierlichen Zustandsüberwachung („*Condition Monitoring*“ - COM) und dem BIT bei der Schadensbewertung sowie dem Einfluss auf die Wartungsintervalle und Laufzeiten dargestellt:




Abbildung 12: Klassifikation von Überwachungskonzepten

Während das BIT den Fehler erst bei Überschreitung der Schadensgrenze erkennt, ermöglicht das COM eine kontinuierliche Bewertung des Schadensverlaufes und in Abhängigkeit von der Diagnosegüte die Initialisierung einer präventiven Maßnahme zum Erhalt der Betriebsfähigkeit. Mit zunehmender Qualität der Diagnose kann der Verlust an operationeller Zeit E minimiert werden. Durch eine nicht perfekte Diagnose wird E in der Realität niemals 0 betragen, jedoch wird im Gegensatz zum BIT eine unzulässige Degradierung während des Betriebes vermieden. Das Ziel bei der Entwicklung von COM sollte somit zur Maximierung der Komponentenlaufzeit neben einem möglichst unkomplizierten Überwachungskonzept mit geringem Einfluss auf die Systemauslegung und den Betrieb auch die Verbesserung der Diagnosegüte sein.

Grundlegend wird zwischen drei verschiedenen Arten von Schadensverläufen unterschieden [68]:

- Konvex
- Linear
- Konkav

Konvexe Verläufe treten üblicherweise bei Ermüdungsbeanspruchungen auf, während lineare Verläufe typisch für Verschleiß und konkave Eigenschaften durch eine abnehmende Degradierungsrate klassifiziert sind. Eine abnehmende Degradierungsrate tritt vornehmlich bei chemischen Prozessen auf, nachdem die Reaktionsenergie der vorhandenen Stoffe mit zunehmender Degradierung abnimmt. Bei gleicher Diagnosegüte ergeben sich unterschiedliche Verluste an operationeller Zeit durch den Austausch der überwachten Komponente:




Abbildung 13: Einfluss des Schadensverlaufes auf die Nutzungsdauer bei konstanter Diagnosegüte

Für die Modellierung wurde der Fehler für den linearen Verlauf E_L als gemittelter Wert verwendet, um den Verlust an operationeller Zeit durch eine erhöhte effektive Austauschrate zu modellieren:

$$\lambda_{\text{Deff}} = \lambda_D \cdot (1 + (1 - \theta_D)) \quad (5.12)$$

Ein weiterer Parameter zur Beschreibung der Diagnosequalität ist die Fehlalarmrate α_{FA} . Diese wurde für BIT und COM individuell vorgegeben, um den Einfluss der Diagnosefunktionen auf die Austauschraten zu modellieren:

$$\lambda_{\text{Feff}} = \lambda \cdot \left(1 + \frac{\alpha_{FA}}{1 - \alpha_{FA}} \right) \quad (5.13)$$

Der letzte Beitrag zur Beschreibung der Diagnosefunktion ist die Fähigkeit zur Fehlerisolation. Eine nicht perfekte Fehlerisolation erfordert zusätzlichen Aufwand zur Bestimmung der Fehlerquelle, indem die potentiellen Kandidaten überprüft werden müssen, bis die fehlerhafte Komponente identifiziert worden ist.

Basierend auf dem in [25] beschriebenen Konzept zur Implementierung von BIT-Funktionen, ist für alle nicht-sicherheitskritischen Fehlerarten eine Wahrscheinlichkeit zur Isolation auf 3 (P_3), 2 (P_2) und 1 (P_1) Komponenten angenommen worden.

Für die Implementierung wurde vorausgesetzt, dass sich die Reparaturzeit aus den folgenden Anteilen zusammensetzt [63]:

- Fehlererkennung
- Fehlerisolation
- Ausbau der fehlerhaften und Einbau der neuen Komponente
- Überprüfung ob die Funktion wieder wie gefordert erfüllt wird

Der Einfluss einer hierauf aufbauenden, nicht perfekten, Fehlerisolation auf die Fehlersuche am operativen System ist in Abbildung 14 veranschaulicht:

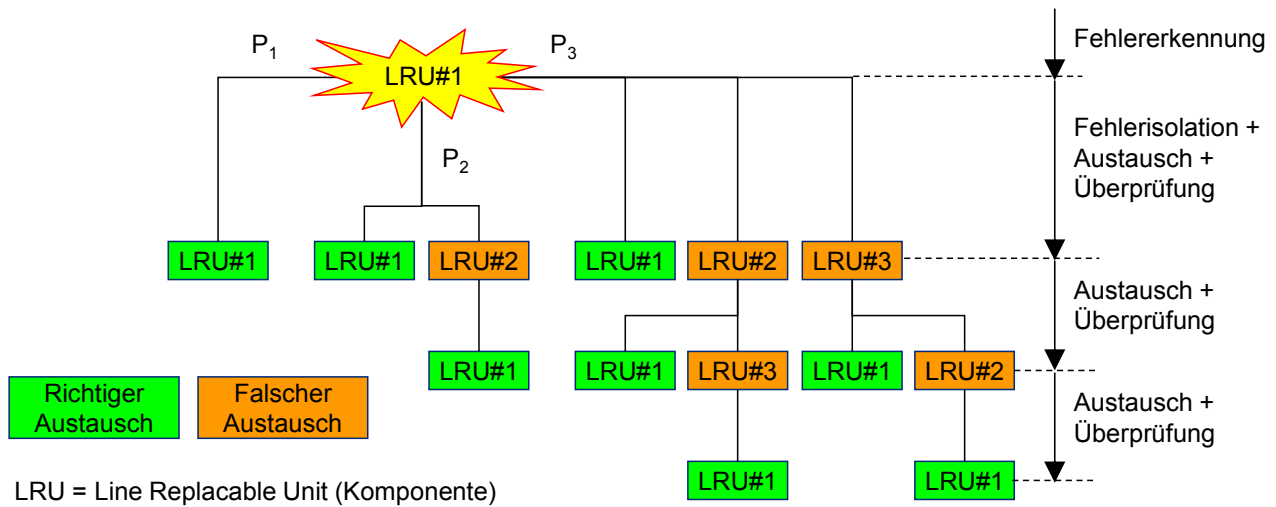


Abbildung 14: Simulationskonzept für nicht perfekte Fehlerisolation

Der beschriebene Ansatz lässt sich beliebig auf n Komponenten (repräsentiert durch $P_1 - P_n$ Wahrscheinlichkeiten und n Entscheidungsbäume mit maximaler Tiefe n) erweitern. Aus der somit erhöhten effektiven Austauschrate ergibt sich ein Faktor für die erhöhte durchschnittliche Reparaturzeit des Systems ohne Berücksichtigung von COM:

$$\Delta T_{RO} = p_1 + \sum_{i=1}^n ((p_i - p_{i-1}) \cdot i \cdot (1 - p_{fdi})) + (1 - p_n) \quad (5.14)$$

mit:

n = Anzahl der möglichen Fehlerquellen

p_i = Wahrscheinlichkeit für Fehlerisolation auf i Komponenten

p_{fdi} = Relativer Anteil der Fehlerisolation an Reparaturzeit ($\approx 0,35$)

Die idealisierte COM-Fehlerisolation liefert wiederum einen Faktor zur Reduzierung der Reparaturzeit:

$$\Delta T_{RC} = 1 - p_{fdi} \quad (5.15)$$

3.4.2. Fehlerprognose

Die Aufgabe einer Fehlerprognose ist die Vorhersage des optimalen Zeitpunktes zur Instandhaltung der überwachten Komponenten. Aufgrund von nicht perfekter Prognose (s. § 2.2) wird der Fehlerbetrag (Genauigkeit) und die Streuung (Präzision) der prognostizierten Größe immer größer Null sein. Daraus resultiert ein Austausch der Komponente zum nicht optimalen Zeitpunkt [69]. In Abhängigkeit von der Kritikalität der überwachten Funktion wird der Austausch deshalb am unteren oder oberen Ende eines Vertrauensbereiches durchgeführt. Als Indikator für das jeweilige Fehlerisiko wird hierzu die Ausfallwahrscheinlichkeit verwendet:




Abbildung 15: Eigenschaften der Prognose für die Modellierung

Die Prognose verhindert ungeplante Instandsetzungsmaßnahmen und somit auch die Wartezeit auf Ersatzteile und Ressourcen. Des Weiteren reduziert die Fehlerprognose die Unsicherheit in der Bestimmung der Systemverfügbarkeit, da durch die Vorhersage des Ausfallzeitpunktes kein Risiko in der Abschätzung der Systemausfallraten besteht. Während alle anderen Kategorien bei der Modellbildung, den durch das Design und den Betrieb bedingten Unsicherheiten im Ausfallverhalten unterliegen¹⁹ (s. § 3.3 und § 3.5.1), wird die Unsicherheit im Ausfallverhalten der durch Prognose überwachten Geräte ausschließlich durch den Prognosefehler bestimmt. Die Bestimmung der effektiven Austauschrate für Komponenten mit Prognosefähigkeiten erfolgt entsprechend (5.16):

$$\lambda_{Peff} = \lambda_P \cdot (1 + \lambda_P \cdot T_L \cdot (1 - \gamma_P \cdot (1 + \delta_P \cdot (1 - \theta_P)))) \quad (5.16)$$

mit:

δ_P = Auslegungskriterium: -1 Konservative Auslegung; +1 Optimistische Auslegung

¹⁹ Zur Gewährleistung eines sicheren Betriebes werden deshalb nach Inbetriebnahme konservative Inspektions- und Instandhaltungszyklen definiert, die bei zunehmender Systemreife gegen ein optimales Intervall konvergieren.

Folgende Annahmen wurden für die Modellierung der Prognosefähigkeit getroffen:

- Fehlerprognose ist nur für COM überwachte Komponenten möglich.
- Der benötigte Prognosehorizont wird aus der logistischen Vorlaufzeit abgeleitet.
- Die Fehlerwahrscheinlichkeit zur Initialisierung einer prädiktiven Maßnahme wird ausreichend klein gewählt um Fehler im Betrieb zu vermeiden.
- Durch die nicht perfekte Prognose werden Komponenten vorzeitig ausgetauscht.
- Degradierungsverläufe, die nicht das Kriterium für den Prognosehorizont erfüllen, werden als präventive CBM Maßnahmen modelliert.
- Die Unsicherheiten zur Bestimmung der Verteilungen für A_0 und SCR werden für die prädiktiven CBM Anteile vernachlässigt.
- Der durch die nicht perfekte Prognose erhöhte Anteil der Austauschrate für Komponenten mit prädiktiven Maßnahmen erhöht die Unsicherheit der Verteilungen für A_0 und SCR.

Somit bietet die Prognose das Potential zur Reduzierung von Wartezeiten und Unsicherheiten bei der Bestimmung von Parametern für die PBC-Analyse. Für große Abweichungen von der idealen Prognose (ausgedrückt durch γ_p und θ_p) kann dieser Vorteil kompensiert und die Systemverfügbarkeit negativ beeinflusst werden. Durch Parameterstudien dieser Kennwerte lassen sich für ein gegebenes Szenario Aussagen über die geforderte Leistungsfähigkeit von Prognosealgorithmen treffen.

3.5. Instandhaltung

Die Frequenz und Dauer der Instandhaltung werden durch die Systemeigenschaften Zuverlässigkeit und Wartungsfreundlichkeit bestimmt. Bei einer weiteren Berücksichtigung von Fehlalarmen und Sekundäreffekten reduziert sich die Zuverlässigkeit des Systems entsprechend. Aufgrund von den in § 2.1.1. genannten Punkten wird für einen CBM-Ansatz auch immer ein nicht unerheblicher Anteil an OCM-Maßnahmen erforderlich sein. Neben dem Bedarf für Routinearbeiten, die in Intervallen durchgeführt werden müssen, werden ebenso nicht alle Fehler, die nicht vernachlässigbare Auswirkungen auf die Sicherheit oder ökonomische Effizienz haben, hinreichend überwachbar sein, weswegen immer auch festgelegte Wartungszyklen ein Bestandteil von zustandsbasierten Instandhaltungskonzepten sein werden. Um diesen Aspekt abzudecken, sind entsprechende Annahmen bei der Modellierung der präventiven Maßnahmen im OCM-Anteil getroffen worden.

Für die Herleitung der Varianzen ist zu berücksichtigen, dass der Fokus bei der Modellbildung auf der Unterstützung der Systementwicklungsphase und der Validierung von Auslegungskriterien lag. In dieser Phase unterliegt das Systemverhalten Annahmen und Unsicherheiten und die wirklichen Fehlerraten können von den theoretischen Vorgaben abweichen. Diese Annahme spielt besonders bei der Implementierung der Prognosefähigkeiten eine Rolle (s. § 3.4.2).

3.5.1. Wartungsmaßnahmen

Die korrektiven Maßnahmen werden aus dem Parametersatz RMT zur Systemauslegung abgeleitet:

$$\lambda_{CORRO} = \lambda_{RMT} \cdot P_{OCM} \cdot P_{CORRO} \quad (5.17)$$

$$\lambda_{CORRC} = \lambda_{RMT} \cdot P_{CBM} \cdot P_{CORRC} \quad (5.18)$$

mit:

λ_{RMT} = Fehlerrate aus Systemdesign

P_i = Wahrscheinlichkeit für Kategorie i

Für eine realistische Abbildung der geplanten Intervalle („Mean Time Between Scheduled Maintenance“ - MTBSM) wird für den präventiven OCM-Anteil zusätzlich die Wahrscheinlichkeit berechnet, dass ein Fehler während des Betriebes eine korrektive Maßnahme erforderlich macht (entspricht einem Fehlerfall zwischen zwei Inspektionen):

$$\lambda_{PREVO} = \lambda_{RMT} \cdot P_{OCM} \cdot P_{PREVO} \quad (5.19)$$

$$p_F = F_{\lambda_{PREVO}} \left(\frac{1}{MTBSM} \right) \quad (5.20)$$


mit:

$F_x(x_i)$ = Kumulative Verteilungsfunktion der Zufallszahl x im Wertebereich $x \leq x_i$

Die verbleibenden Fehlerraten werden zu einem fixen Wartungsintervall zusammengefasst:

$$\lambda_{PREVOeff} = \frac{1}{MTBSM} \quad (5.21)$$

Diese Zusammenhänge sind nachfolgend für eine idealisierte Verteilung von λ_{PREVO} dargestellt:



MTBSM: Mean Time Between Scheduled Maintenance

Abbildung 16: Einfluss des fixen Wartungsintervalls auf die Systemzuverlässigkeit

Die Vorgabe des inversen Wartungsintervalls als Austauschrate für die zugeordneten Komponenten entspricht einer Wiederherstellung der ursprünglichen Fehlerwahrscheinlichkeit und somit einer idealisierten Instandsetzung. Der mit (5.20) berechnete Anteil, der zu Ausfällen zwischen zwei Wartungsintervallen führt, wird zu den korrektiven Maßnahmen gezählt, da die aufgetretenen Fehler entsprechend behoben werden müssen:

$$\lambda_{CORROeff} = \lambda_{CORRO} + (1 - p_F) \cdot \lambda_{PREVO} \quad (5.22)$$

Für die anderen CBM Kategorien λ_{PREDC} und λ_{PREVC} erfolgt die Herleitung analog zu (5.18) und unter Berücksichtigung der nicht perfekten Diagnose & Prognose (s. § 3.4), so dass sich die resultierenden Austauschraten für den OCM- und CBM-Anteil wie folgt ergeben:

$$\lambda_{OCM} = \lambda_{CORROeff} \cdot (1 + P_{SFLT}) + \lambda_{RMT} \cdot P_{OCM} \cdot \frac{\alpha_{FA,BIT}}{1 - \alpha_{FA,BIT}} \quad (5.23)$$

$$\begin{aligned} \lambda_{CBM} &= \lambda_{CORRC} \cdot (1 + P_{SFLT}) + \lambda_{PREVC} \cdot (1 + \varepsilon_D) + \dots \\ &\lambda_{RMT} \cdot P_{CBM} \cdot \frac{\alpha_{FA,COM}}{1 - \alpha_{FA,COM}} + \lambda_{PREDC} \cdot (1 + \varepsilon_P) \end{aligned} \quad (5.24)$$

wobei:

$$\varepsilon_D = \theta_D$$

$$\varepsilon_P = \lambda_{PREDC} \cdot T_L \cdot (1 - \gamma_P \cdot (1 + \delta_P \cdot (1 - \theta_P)))$$

Für die nicht perfekte Fehlerisolation des BITs im OCM-Anteil erhöht sich zusätzlich die Wahrscheinlichkeit für einen wartungsinduzierten Fehler (s. § 3.4.1):

$$P_{SMNTEff} = P_{SMNT} \cdot \left(p_1 + \sum_{i=1}^n ((p_i - p_{i-1}) \cdot i) + (1 - p_n) \right) \quad (5.25)$$

Somit lassen sich die durch Wartungsfehler erhöhten effektiven Austauschraten bestimmen:

$$\lambda_{SMNTOeff} = \lambda_{OCM} \cdot P_{SMNTEff} \quad (5.26)$$

$$\lambda_{SMNTC} = \lambda_{CBM} \cdot P_{SMNT} \quad (5.27)$$

Die fixen Wartungsintervalle erhöhen hierbei nicht zusätzlich die Gesamtaustauschrate, da das System während dieser Maßnahmen nicht verfügbar ist und durch die konstante Wartungsdauer zusätzliche sekundäre Fehler die Verfügbarkeit nicht weiter beeinflussen. Die effektive Gesamtaustauschrate ergibt sich somit zu:

$$\lambda_{eff} = \lambda_{OCM} + \lambda_{SMNTOeff} + \lambda_{PREVOeff} + \lambda_{CBM} + \lambda_{SMNTC} \quad (5.28)$$

Eine Korrelation und damit die Notwendigkeit die entsprechenden Kovarianzen zu bestimmen besteht hierbei für alle Sekundäreffekte (ausführliche Herleitung s. Anhang B).

Da das fixe Wartungsintervall feste Werte für den Startpunkt und die Dauer hat, kann die zugehörige Unsicherheit in der Abschätzung der Fehlerraten vernachlässigt werden. Die Kovarianz des prädiktiven CBM-Anteils kann ebenfalls vernachlässigt werden, da nur die Varianz des Prognosefeh-

lers und nicht der Prognose selber berücksichtigt wird (für eine ausführliche Herleitung der Varianzen für den Anteil Diagnose & Prognose s. Anhang B).

Um die Berechnung der Systemverfügbarkeit zu ermöglichen, müssen die effektiven Anteile der geplanten (λ_g) und ungeplanten (λ_u) Maßnahmen bestimmt werden (Herleitung der entsprechenden Varianzen s. Anhang B):

$$\lambda_{geff} = \lambda_{PREDC} \cdot (1 + \varepsilon_P) + \lambda_{PREVOeff} \quad (5.29)$$

$$\lambda_{ueff} = \lambda_{OCM} + \lambda_{SMNTOeff} + \lambda_{CBM} - \lambda_{PREDC} \cdot (1 + \varepsilon_P) + \lambda_{SMNTC} \quad (5.30)$$

Somit sind können alle Austauschraten und zugehörigen Varianzen unter Berücksichtigung von Primärfehlern und Sekundäreffekten, der Leistungsfähigkeit des Zustandsüberwachungssystems und einer beliebig auf das Systemdesign angepassten Instandhaltungsstrategie bestimmt werden.

3.5.2. Reparaturzeiten

Des Weiteren wird für die Bestimmung der Systemverfügbarkeit ein Ausdruck für die mittlere Reparaturzeit benötigt. Dieser lässt sich auf Systemebene aus den Reliability und Maintainability Vorgaben für jede Komponente als mit den einzelnen Fehlerraten gewichteter Mittelwert herleiten [63]:

$$T_R = \frac{\sum_{k=1}^n \lambda_k \cdot T_{Rk}}{\sum_{k=1}^n \lambda_k} \cdot \left(\frac{\lambda_{TO} \cdot \Delta T_{RO} + \lambda_{TC} \cdot \Delta T_{RC}}{\lambda_{TO} + \lambda_{TC}} \right) \quad (5.31)$$

wobei:

$$\lambda_{TO} = \lambda_{CORROeff}$$

$$\lambda_{TC} = \lambda_{CORRC} + \lambda_{PREVC} + \lambda_{PREDC}$$

Für die Einführung der Korrekturfaktoren infolge der Fehlerisolationsfähigkeiten entsprechend (5.14) und (5.15) wird angenommen, dass sich die sekundären Fehler gleichmäßig über alle Systemelemente verteilen. Die effektive Größe ist wiederum ein Mittelwert aus der komponentenspezifischen Reparaturzeit und festgelegten Dauer der fixen Wartungsintervalle („*Mean Time To Maintenance*“ - MTM):

$$T_{Reff} = \frac{(\lambda_{eff} - \lambda_{PREVOeff}) \cdot T_R + \lambda_{PREVOeff} \cdot MTM}{\lambda_{eff}} \quad (5.32)$$

mit:

$$\kappa_{TReff} = 1,1 \text{ für } \kappa_x \text{ in (5.4) und } E[x] = T_{Reff} \text{ in (5.5) für Reparaturzeiten}$$

Mit der Bestimmung der effektiven Reparaturzeit ist das Ergebnis der RMT-, MNT- und EHM-Betrachtung vervollständigt und es wird lediglich noch ein Ausdruck für die Verfügbarkeit von Ersatzteilen (LOG) benötigt, um die resultierende operationelle Leistungsfähigkeit zu berechnen.

3.6. Ersatzteilversorgung

Die Ressourcenbevorratung ist einer der wichtigsten Faktoren zur Beeinflussung der Systemverfügbarkeit. Unter Vernachlässigung der Arbeitskräfteplanung (s. § 3) wird an dieser Stelle nur die Ersatzteilbevorratung betrachtet. Zur Gewährleistung der operationellen Verfügbarkeit müssen häufig große Mengen an Ersatzteilen bereitgestellt werden, wovon nicht alle benötigt werden und stattdessen nicht vorhandene Ersatzteile zu Systemstandzeiten führen. Die Streuung für ungeplante Maßnahmen wird verwendet, um die Unsicherheit bei der Ersatzteilbevorratung zu modellieren:




Abbildung 17: Herleitung der logistischen Wartezeit für FR = 95%

Durch die Füllrate (FR) wird die Ersatzteilbevorratung abgebildet. Sie gibt an, wie groß die Wahrscheinlichkeit ist, dass ein benötigtes Ersatzteil verfügbar ist. Eine Bevorratung anhand des Erwartungswertes λ_{ueff} würde entsprechend der Form der Verteilung ein Risiko zur Unterversorgung und damit einer erhöhten Wartezeit bedeuten. Ausschließlich wenn die FR gegen 100% strebt ($\lambda_f \rightarrow \infty$), kann zu jedem Zeitpunkt das benötigte Ersatzteil zur Verfügung gestellt werden. Somit kann ein Ausdruck für den Erwartungswert und die Varianz der mittleren Wartezeit hergeleitet werden:

$$T_W = \frac{\lambda_{geff} \cdot T_0 + \lambda_{ueff} \cdot T_{LDT}}{\lambda_{eff}} \quad (5.33)$$

wobei:

$$T_{LDT} = \left(1 - \int_{-\infty}^{\lambda_f} f(\lambda_u) d\lambda \right) \cdot p_L \cdot T_L + T_0$$

mit:

λ_f = Abdeckungsrate für Ersatzteilbevorratung

p_L = Faktor für Vorlaufzeit ($\sim 0,5$ für fixe Intervalle; ~ 1 für bedarfsorientierte Intervalle)

$f(\lambda_u)$ = Dichterverteilung der Austauschrate für ungeplante Maßnahmen

κ_W = 1,1 für κ_x in (5.4) und $E[x] = T_W$ in (5.5) für Wartezeiten

Unter Verwendung von (5.1)-(5.3) und (5.29)-(5.30) sowie den Ausdrücken für die entsprechenden Varianzen und den Rechenregeln für Zufallszahlen aus Anhang B lassen sich unter Vorgabe eines Szenarios die Erwartungswerte von A_0 , MID und SCR sowie die zugehörigen Varianzen bestimmen. Das Ergebnis kann entweder direkt zur Bewertung der operationellen Leistungsfähigkeit verwendet werden oder mittels (5.11) die PBC-Analyse unterstützen.

3.7. Modellvalidierung

Die Zielsetzung bei der Validierung war, anhand des Vergleiches mit einer zertifizierten und industriell im Einsatz befindlichen Simulationsumgebung die konzeptionelle und mathematische Implementierung des MMDL zu bestätigen. Die hierfür genutzte Umgebung ist die OPUS / Simlox Suite der Firma Systecon. Diese wurde entwickelt, um für ein gegebenes Systemdesign und Instandhaltungskonzept den Bedarf an Ersatzteilen und die damit erreichbare Systemverfügbarkeit abzuschätzen. Zwar bietet OPUS / Simlox eine Vielzahl an weiteren Funktionalitäten zur Bewertung eines Systementwurfs und Betreiberkonzeptes²⁰, für die Validierung des MMDL sind die genannten Anteile jedoch hinreichend geeignet.

3.7.1. Vorgehensweise

Die beiden Module (OPUS / Simlox) bauen funktional aufeinander auf. Der erste Schritt besteht darin, das gesamte Systemdesign durch eine Gruppierung von Fehlerraten und Reparaturzeiten zu definieren sowie die Klassifikation in korrektive und präventive Maßnahmen vorzunehmen. Zusätzlich ist eine Vorgabe der Parameter Missionsdauer, Anzahl der Segmente pro Missionseinsatz, Laufzeit der Missionen, Auslastungsrate während der Nutzungsdauer und Verteilung der Standorte (operationell und Instandhaltung) erforderlich. Ausgehend von diesen Vorgaben bestimmt OPUS arithmetisch gemittelte Werte für die Systemverfügbarkeit und Erfolgsraten der Missionsanteile als Funktion der FR für Ersatzteile. Daraus kann wiederum eine gemittelte FR auf Systemebene abgeleitet und somit ein direkter funktionaler Zusammenhang zur Verfügbarkeit hergestellt werden.

Der Simlox Anteil stellt eine Plattform zur detaillierteren Analyse mittels ereignisbasierten Monte-Carlo Simulationen dar, wobei ausgehend von den OPUS-Datenpunkten für die Ersatzteilbevorratung eine Simulation mit stochastischem Ausfallverhalten jeder einzelnen Komponente über den angegebenen Zeitraum durchgeführt wird. Anhand einer vorgegebenen Anzahl an Simulationsläufen werden schließlich der Erwartungswert und die zugehörigen Vertrauensbereiche der Verfügbarkeit als Funktion der Ersatzteilbevorratung bestimmt. Hierbei bietet Simlox zusätzliche Möglichkeiten das Logistikkonzept detailliert abzubilden. Während bei OPUS lediglich ein fixes Versorgungs-

²⁰ Für weitere Details sei auf die Internetseite <http://www.systecon.se/> verwiesen. Die Nutzung der Produkte ist lizenzpflichtig und konnte aufgrund der anfallenden Kosten zur Unterstützung der Modellvalidierung nur über einen sehr begrenzten Zeitraum ermöglicht werden.

intervall angegeben werden kann, besteht bei Simlox die Möglichkeit, die Versorgung mit Ersatzteilen dynamisch zu gestalten. Wie bei Monte-Carlo Simulationen allgemein üblich, steigt die Qualität der Aussage von Simlox mit dem Verhältnis zwischen Laufzeit und Ereignisrate des betrachteten Szenarios und der Anzahl der durchgeführten Simulationen.

Das beschriebene Zusammenspiel der beiden Simulationsumgebungen ist in [Abbildung 18](#) veranschaulicht:

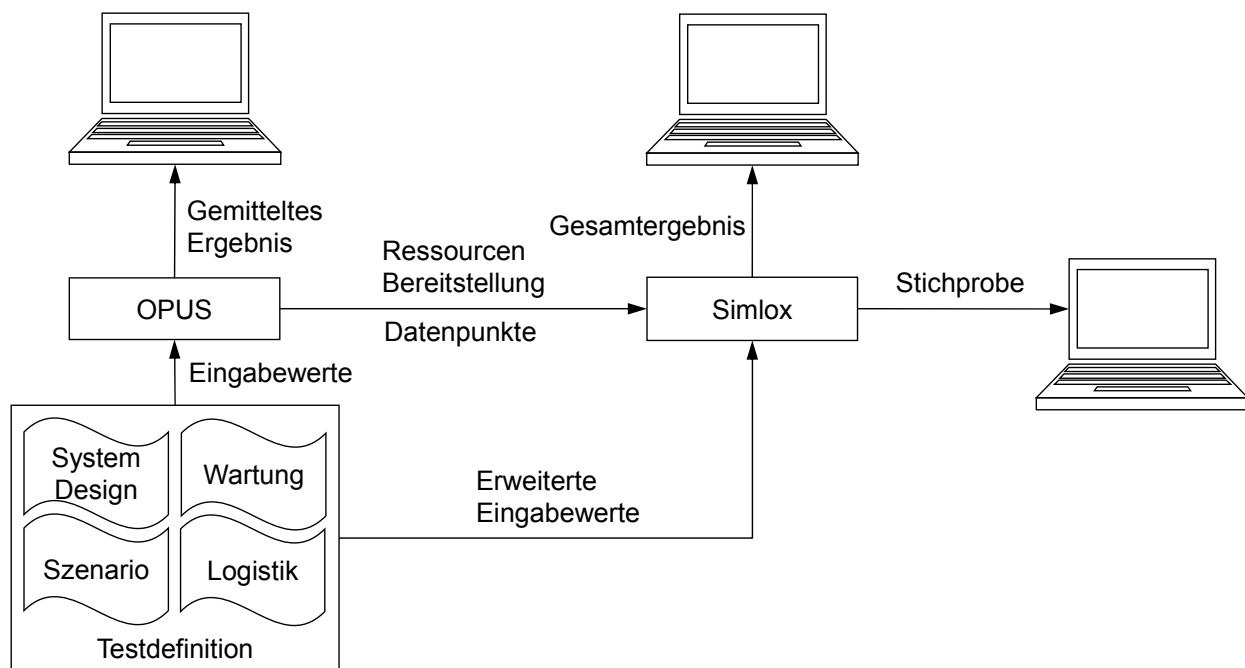


Abbildung 18: Systecon Simulationsumgebung

Die Validierung des MMDL ist phasenweise durch beide Module vorgenommen worden. Die Ausgabewerte von OPUS werden genutzt, um die Vorgehensweise zur Bestimmung der Erwartungswerte zu bestätigen. Simlox diene zusätzlich dazu, um anhand des Abgleichs der Vertrauensbereiche den stochastischen Anteil der Modellierung zu validieren. Da das MMDL ebenso wie OPUS mit gemittelten Werten rechnet und Simlox eine pseudo-empirische Analyse durchführt, ist der Abgleich zwischen MMDL und OPUS aussagekräftiger als der Vergleich mit Simlox. Eine Abweichung in den Erwartungswerten zwischen dem MMDL und Simlox ist aufgrund der Unterschiede im Simulationskonzept somit weniger zu gewichten als zwischen OPUS und dem MMDL. Zur Bestätigung des Simulationskonzeptes von Unsicherheiten ist jedoch der Abgleich der relativen Streuung der Ausgabewerte des MMDLs und von Simlox ein maßgebliches Bewertungskriterium.

Die beschriebene Vorgehensweise zur Modellvalidierung mit Anbindung an die Risikoanalyse von PBC-Konzepten ist in [Abbildung 19](#) schematisch dargestellt:

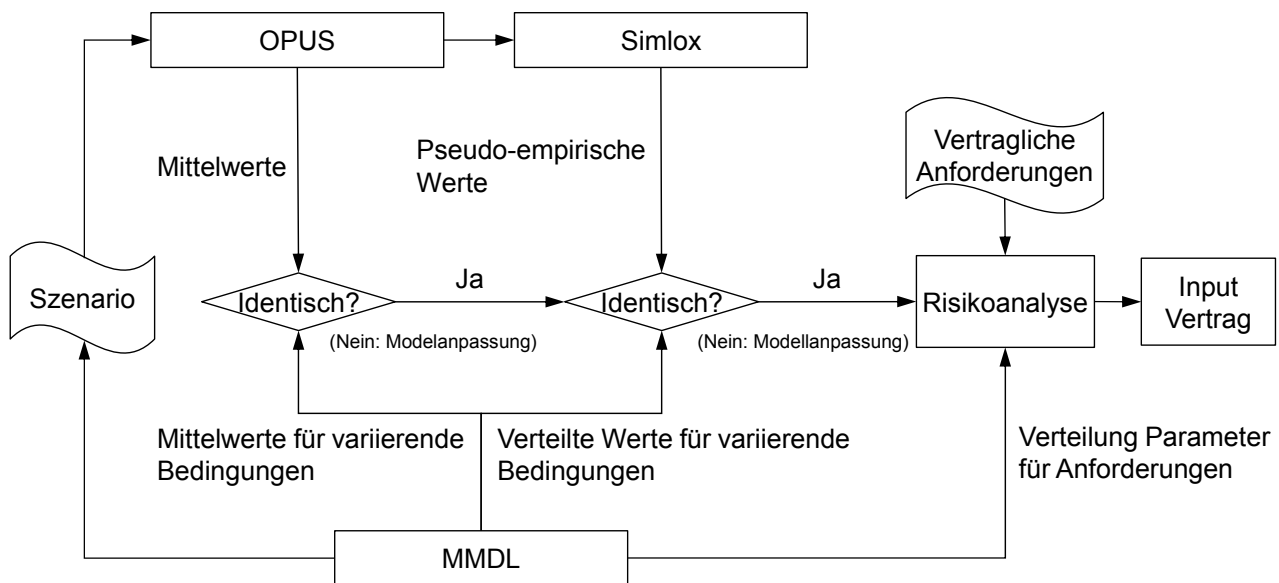


Abbildung 19: Simulationskonzept für MMDL Validierung

Durch die schrittweise Validierung war es zunächst möglich anhand des Abgleichs der MMDL Ergebnisse mit den OPUS Ausgabewerten das allgemeine Konzept zu überprüfen. Ausgehend von den in (5.2) und (5.3) verwendeten Parametern und der Zielsetzung unterschiedliche Wartungsphilosophien zu betrachten, wurde hierzu der Einfluss und damit auch die Implementierung folgender Modellgrößen untersucht:

- Auslastungsrate (UR)
- Versorgungsintervalle (T_W)
- Einheitliches oder hybrides Instandhaltungskonzept (Korrektiv; Korrektiv & Präventiv)
- Operationelles Szenario im Systemverbund (SCR)

Um abzuschätzen zu können, wie aussagekräftig die Bestimmung der Vertrauensbereiche für eine bestimmte Parameterkonstellation ist, wurde hierfür zunächst der Einfluss der Nutzungsdauer und Anzahl von Simulationsläufen auf die Stabilität der Ergebnisse von Simlox untersucht.

Durch die Turnaroundzeiten wird die Verfügbarkeit der Luftsegmente zusätzlich reduziert. Für eine detailliertere Betrachtung sollte diese nur bei einem Systemausfall und zur Vorbereitung des Ersatzsystems berücksichtigt werden, da bei einem geplanten Wechsel von zwei Luftsegmenten die vorbereitenden Maßnahmen stattfinden, während die Mission noch unterstützt wird. Zur Implementierung ist der entsprechende Anteil der Standzeiten mit dem Verhältnis der kritischen und unkritischen Fehlerfälle zu normieren. Zur Reduzierung der Komplexität und weil dadurch das Ergebnis zugunsten des CBM-Anteils beeinflusst worden wäre, ist dieser Aspekt vernachlässigt worden, ohne damit die Bewertung der CBM-Fähigkeit nachteilig zu beeinflussen.

Nach einem erfolgreichen Vergleich zwischen dem MMDL und OPUS / Simlox, kann das MMDL aufgrund der Technologiereife der Syscon Suite für den untersuchten Gültigkeitsbereich als validiert angenommen werden.

Aufgrund der fehlenden Fähigkeiten der OPUS / Simlox Suite konnten folgende MMDL-Eigenschaften nicht oder nur teilweise validiert werden:

- Einfluss der Fehlerisolationfähigkeit auf die Reparaturzeiten (erhöhte Reparaturzeit)
- Implementierung von prädiktiven Wartungskonzepten (nicht durchgeführt)
- Wahrscheinlichkeit für Fehler vor präventiver Wartung (nicht durchgeführt)
- Sekundäre Fehlereffekte (gleichmäßig über die Systeme verteilte erhöhte Fehlerraten)

Eine Simulation der prädiktiven CBM-Anteile könnte in der OPUS Umgebung durch eine FR von 100% für die ausgewählten Komponenten umgesetzt werden, ohne diesen Anteil bei der Gesamtfüllrate zu berücksichtigen. Somit lässt sich der Einfluss der prädiktiven Wartung auf die Erwartungswerte auch aus dem generellen Zusammenhang zwischen FR und Verfügbarkeit validieren. Für Simlox müsste der Ansatz zur Vernachlässigung der Unsicherheiten durch einen fixen Ausfallzeitpunkt simuliert werden, was mit der Syscon Suite nicht umsetzbar ist, da für alle Fehlerraten der gleiche Verteilungstyp unterstellt wird.

Die Auswirkungen der Fehlerfälle, die eigentlich durch ein fixes Wartungsintervall verhindert werden sollen, können zwar nicht quantitativ validiert werden, jedoch kann qualitativ nachgewiesen werden, dass die erreichbare Verfügbarkeit durch zusätzliche Wartungsmaßnahmen reduziert wird.

3.7.2. Verwendetes Szenario

Die Auswahl des Szenarios für die Modellvalidierung sollte einen hinreichend komplexen Testfall bieten, um basierend auf einem detaillierten Systementwurf die Mittelwertbildung durch die Modellgleichungen bewerten zu können. Hierzu ist als Missionsziel (SCR) die Bereitstellung einer Aufklärungsleistung durch ein entsprechend ausgerüstetes Luftfahrtgerät über einen zunächst unbegrenzten Zeitraum angenommen worden. Das operative System besteht aus drei Luftsegmenten und einem Bodensegment zur Koordination der Missionselemente. Für die Erfüllung der SCR müssen jeweils ein Luftsegment und ein Bodensegment operationell verfügbar sein. Falls eines der Luftsegmente ausfällt, kann der Missionsanteil von einem der beiden anderen übernommen werden. Somit stehen für das Luftsegment jeweils zwei Ersatzsysteme zur Verfügung und die Mission kann nur bedient werden, wenn mindestens ein Luftsegment und das Bodensegment verfügbar sind.

Der Segmentaufbruch in Systeme, Subsysteme und Komponenten ist in Abbildung 20 exemplarisch dargestellt:

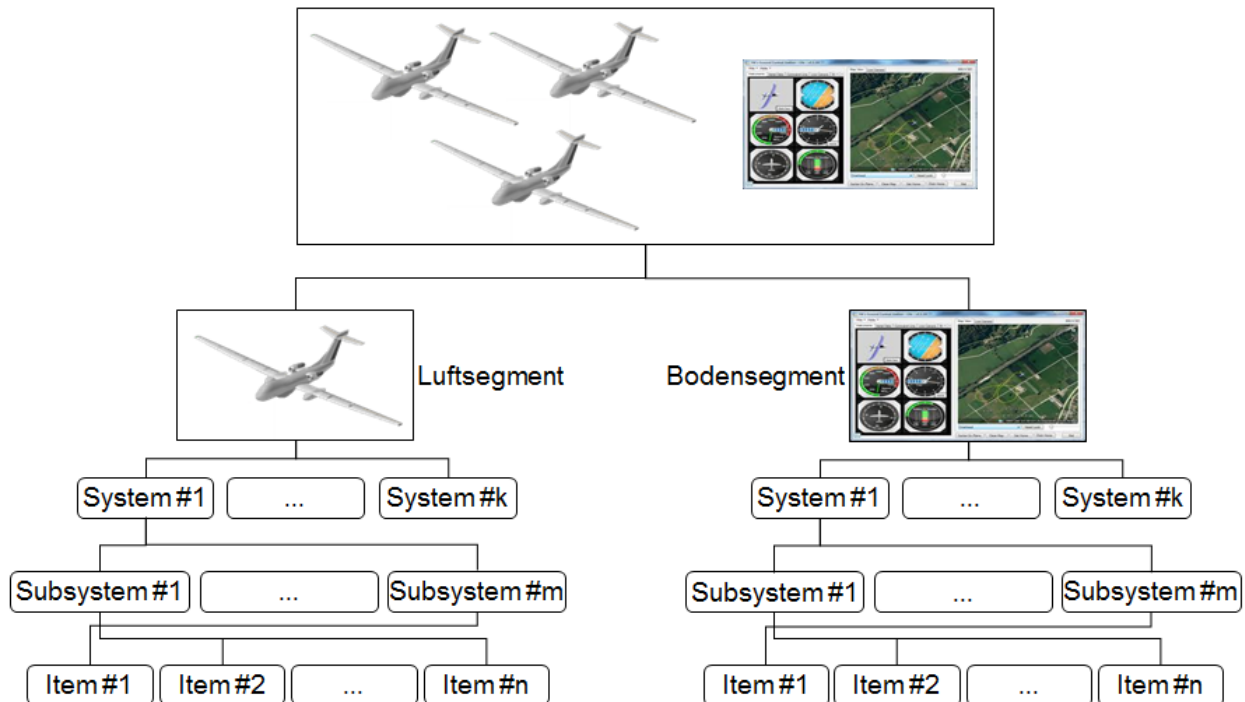


Abbildung 20: Operationelles Szenario für MMDL Validierung

Die Zahlenwerte für die Systemauslegung (Reliability & Maintainability) sind ausgehend von einer repräsentativen Verteilung aus vergleichbaren Anwendungen in der Luftfahrt mittels eines Zufallszahlengenerators erstellt worden. Hierzu wurden der Mittelwert und die Standardabweichung der ursprünglichen Verteilung durch einen linearen Offset- und Skalierungsfaktor modifiziert und gleichverteilte Größen angenommen.

Falls nicht anders beschrieben wird für jeden Testfall eine reine OCM-RTFM-Strategie simuliert. Die Ergebnisse sind übertragbar auf eine beliebige Kombination von korrektiven und präventiven Wartungsanteilen aus dem OCM- und CBM-Bereich, da hierfür lediglich geänderte Fehlalarmraten (BIT / COM) und eine Reduzierung der Sekundäreffekte sowie eine Erhöhung der präventiven Anteile durch die nicht perfekte Diagnose (CBM präventiv) berücksichtigt werden müssen.

Alle weiterhin benötigten Modellparameter wurden so gewählt, dass für die Basisauslegung mit einer OCM-RTFM-Strategie eine SCR von >90% erreicht werden konnte und CBM eine Steigerung der Diagnosegüte von ~50% ermöglicht hat. Die Diskussion der exakten Modellparametrisierung ist für die Ergebnisse der Validierung nicht relevant, da hierfür lediglich der Vergleich zwischen dem MMDL und OPUS / Simlox zur Bewertung verwendet wird.

3.7.3. Ergebnisse

Für die Auswertung der Ergebnisse auf Segmentebene ist jeweils die Systemverfügbarkeit als Funktion der FR verwendet worden und entsprechend für das Gesamtsystem die resultierende SCR. Zusätzlich zum Erwartungswert liefert Simlox die 5% sowie das MMDL die 5% und 95% Perzentile

um die Parameterstreuung zu vergleichen. Ein Abgleich der oberen Vertrauensgrenze war nicht möglich da Simlox nur die 5% Perzentile ausgibt.

Um das Modellverhalten auf Segmentebene und im Systemverbund zu diskutieren sind in Abbildung 21 die mit den gewählten Modellparametern erreichbaren Verfügbarkeiten für das Luft- und Bodensegment sowie die resultierende SCR dargestellt. Die Ergebnisse der darüber hinaus durchgeführten Validierungsschritte sind in Anhang C zusammengefasst.

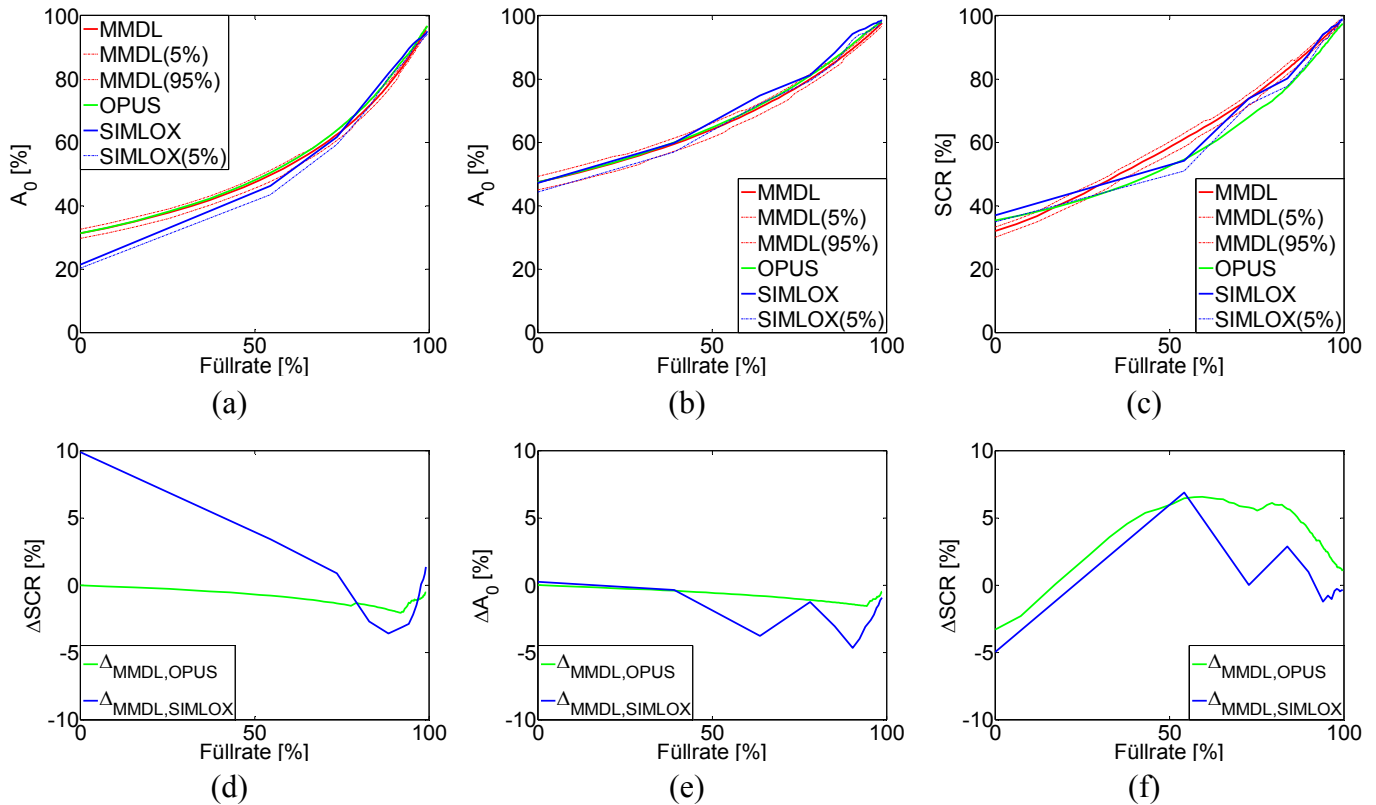


Abbildung 21: Systemverhalten: (a) Luftsegment, (b) Bodensegment, (c) Systemverbund, (d) Residuen MMDL und OPUS / Simlox Luftsegment, (e) Residuen MMDL und OPUS / Simlox Bodensegment, (f) Residuen MMDL und OPUS / Simlox Systemverbund

Im Allgemeinen lässt sich beobachten, dass wie erwartet die erreichbare Verfügbarkeit mit der FR zunimmt. Der exponentielle Trend der Verläufe resultiert aus dem hyperbelähnlichen Charakter von (5.2). Aufgrund der Systemzuverlässigkeit wird auch für eine FR von 0% (jede Reparaturmaßnahme benötigt die Anforderung von entsprechenden Ressourcen) eine Verfügbarkeit von $A_0 > 0\%$ erreicht. Andererseits wird durch die Reparatur- und Turnaroundzeiten auch für eine FR von 100% nur eine Verfügbarkeit von $A_0 < 100\%$ erreicht.

Aufgrund der höheren Zuverlässigkeit (bedingt durch eine geringere Systemkomplexität) des Bodensegments ist $A_{0Boden} > A_{0Luft}$. Durch $UR_{Boden} = 1$ ist hier auch eine gute Übereinstimmung zwischen OPUS und Simlox erkennbar. Die resultierende SCR liegt jeweils aufgrund der ODER/UND Verknüpfung von Luft- und Bodensegment zwischen A_{0Boden} und A_{0Luft} . Während sich für A_{0Boden} und A_{0Luft} über den gesamten Wertebereich ein annähernd identischer Verlauf zwischen OPUS und

dem MMDL beobachten lässt, weist die SCR in Abhängigkeit von der FR Abweichungen zwischen der Sysstecon Suite und dem MMDL auf. Hieraus lässt sich schließen, dass die Bestimmung der Leistungsparameter auf Segmentebene weitestgehend zuverlässig vorgenommen werden kann, während eine Bestimmung der SCR mit der Komplexität des Systemverbundes und dem geforderten Missionsprofil zunehmend ungenauer wird.

Motiviert von diesem Ergebnis und weil der Systemaufbruch des Luftsegments komplexer als die Architektur des Bodensegments ist, wird die Potentialanalyse der Zustandsüberwachung auf Luftsegmentebene durchgeführt.

Zusammenfassend lässt sich aussagen, dass die Validierung des MMDL für alle betrachteten Modelleinstellungen erfolgreich war und aufgrund der in § 3.7.1 und § 3.7.2 genannten Punkte auch auf alle nicht mit der Sysstecon Suite abbildbaren Modelleigenschaften übertragbar ist.

3.8. Potentialanalyse der Zustandsüberwachung

Für die Potentialanalyse der Zustandsüberwachung sind für das beschriebene System- und Betreiberkonzept jeweils die folgenden Szenarien untersucht worden:

- Ersetzen von korrektiven Maßnahmen im OCM-Anteil durch korrektive Maßnahmen im CBM-Anteil (Einfluss der verbesserten Fehlerdiagnose)
- Ersetzen von korrektiven Maßnahmen im OCM-Anteil durch präventive Maßnahmen im CBM-Anteil (Einfluss der verbesserten Fehlerdiagnose und Vermeidung von Folgefehlern)
- Ersetzen von korrektiven Maßnahmen im OCM-Anteil durch prädiktive Maßnahmen im CBM-Anteil (Einfluss verbesserte Fehlerdiagnose, Vermeidung von Folgefehlern sowie eine optimierte Ersatzteilverfügbarkeit und Planungssicherheit)

Durch den Vergleich dieser drei Szenarien anhand des Einflusses auf den Maintenance Index (Wartungsaufwand) und die Verfügbarkeit (operationelle Leistungsfähigkeit) soll für die festgelegten Modellparameter der stufenweise Ausbau von einem reinen OCM-Konzept zu einer voll funktionsfähigen CBM-Strategie bewertet werden.

3.8.1. Fehlerdiagnose

Mit der verbesserten Fehlerisolation auf Komponentenebene wird entsprechend (5.14) und (5.15) durch eine geringere Reparaturzeit hauptsächlich der Wartungsaufwand reduziert (s. [Abbildung 22](#)). In die Erhöhung der Verfügbarkeit fließt zusätzlich der Einfluss der geringeren Austauschrate auf die Wartungsfehler mit ein. Im Mittel wird bei einer Reduzierung des MID von $\approx 40\%$ eine Steigerung für A_0 von $\approx 9\%$ erzielt. Die Unsicherheiten in der operativen Planung und damit auch der Einfluss auf eine Risikobetrachtung bleiben für A_0 nahezu unverändert. Durch die präventive und zustandsbasierte Wartung (s. [Abbildung 23](#)) wird ähnlich wie bei der Verbesserung der Fehlerdiagno-

se im Wesentlichen der MID reduziert. Die durch präventive Maßnahmen verhinderten Folgefehler und alle damit in Zusammenhang stehenden Effekte ermöglichen eine zusätzliche Verbesserung beider betrachteten Parameter (MID -2%, A_0 +1%). Für beide Szenarien ist das Verbesserungspotential im Wesentlichen in dem reduzierten Wartungsbedarf zu sehen. Eine Optimierung der Planungsunsicherheiten für die operationelle Leistungsfähigkeit ist nicht erreicht worden, obgleich die Verbesserung in den Erwartungswerten für A_0 für ein PBC-Szenario eine starke Motivation zur Entwicklung der entsprechenden Zustandsüberwachung wäre. Unter Berücksichtigung eines realen Systementwurfs muss jedoch berücksichtigt werden, dass eine Steigerung der Diagnosefähigkeiten ($P_{CBM} \cdot P_{iC}$) über einen gewissen Prozentwert nicht als realistisch anzusehen ist. Ein Großteil der Komponenten und Funktionen in einem Luftfahrtsystem bieten aufgrund ihrer Bau- und Betriebsweise nicht die notwendigen Grundlagen für eine kontinuierliche Zustandsüberwachung und perfekte Fehlerisolation entsprechend den für die Simulation vorausgesetzten Annahmen.




Abbildung 22: Einfluss Fehlerdiagnose mit COM: (a) Wartungsaufwand, (b) Verfügbarkeit




Abbildung 23: Einfluss präventive Wartung mit COM: (a) Wartungsaufwand, (b) Verfügbarkeit

3.8.2. Fehlerprognose

Die Simulation der prädiktiven CBM-Strategie veranschaulicht deutlich das Potential von Prognose (s. [Abbildung 24](#)). Sowohl die Planung der Wartungsmaßnahmen als auch die geschätzte Systemverfügbarkeit unterliegen einem reduzierten Risiko, bis zur Möglichkeit für eine 100% CBM-Fähigkeit ($P_{CBM} \cdot P_{PREDC}$) annähernd vollständige Planungssicherheit zu erzielen. Durch die Annahme das Prognose eine perfekte Fehlerisolation voraussetzt und die prädiktive Maßnahme ähnlich

wie bei einem präventiven Konzept Folgefehler vermeidet, lässt sich neben der erhöhten Planungssicherheit auch eine deutliche Verbesserung des MID erzielen. Solange der Prognosehorizont das Mindestkriterium der logistischen Vorlaufzeit erfüllt (s. § 3.4.2), ermöglicht die Vorhersage des Ausfallzeitpunktes zusätzlich eine Unabhängigkeit von der aktuellen FR. Durch die kombinierten Eigenschaften der Prognose, den Wartungsaufwand zu reduzieren und gleichzeitig den Ersatzteilbedarf zuverlässig vorherzusagen, lässt sich für das betrachtete Szenario eine Steigerung der Verfügbarkeit von bis zu $\approx 35\%$ erzielen. Auch diese Betrachtung ist für ein fliegendes System nicht vollumfänglich umsetzbar, da der hierfür benötigte Ausbau des Zustandsüberwachungssystems aus § 3.8.1 den Kreis der möglichen Komponenten und Funktionen zusätzlich einschränkt. Es bleibt jedoch festzuhalten, dass bereits eine Fähigkeitsrate von 10% eine ebenso große Steigerung der Verfügbarkeit ermöglicht und somit vor dem Hintergrund von PBC-Konzepten eine starke Motivation zur Entwicklung der hierfür benötigten Fähigkeiten liefert.




Abbildung 24: Einfluss prädiktive Wartung: (a) Wartungsaufwand, (b) Verfügbarkeit

3.8.3. Risikoanalyse für PBC-Konzepte

Basierend auf einer angestrebten Verfügbarkeitsgarantie von 80% für das Luftsegment ist die Betrachtung des Potentials für ein PBC-Konzept in [Abbildung 25](#) dargestellt.

Während sich für die ersten beiden Szenarien aufgrund des geringeren Einflusses auf die erreichbare Steigerung der Verfügbarkeit und Planungssicherheit keine Reduzierung des Risikos erzielen lässt, bietet der prädiktive CBM-Ansatz bei entsprechender Ausbaustufe die Möglichkeit zur Senkung des Vertragsrisikos auf bis zu 0%. Somit ist nachgewiesen, dass ein Vorhaben zur Gewährleistung von PBC-Kennzahlen für ein gegebenes Systemdesign einen starken Anreiz zur Implementierung von Prognosefähigkeiten bietet.

Im Vergleich zu den vorherigen MID- und A_0 -Analysen lässt sich für die durchgeführte Risikoanalyse jedoch sagen, dass für das betrachtete Szenario eine bemerkbare Reduzierung des Vertragsrisikos erst bei einer Leistungsfähigkeit erzielt wird, die für reale Systeme nicht erreichbar sein wird. In diesem Fall müsste neben der Verbesserung der Zustandsüberwachung und Instandsetzung auch das Systemdesign optimiert, bzw. die Vertragsinhalte entsprechend angepasst werden.




Abbildung 25: PBC-Risikoanalyse für SCR = 80%: (a) CBM Korrektiv, (b) CBM Präventiv, (c) CBM Prädiktiv

3.8.4. Zusammenfassung und Ausblick

Die untersuchten Szenarien haben deutlich gemacht, dass bereits die Verbesserung der Fehlerisolationsfähigkeiten einen merklichen Einfluss auf den benötigten Wartungsaufwand und die erreichbare Verfügbarkeit hat. Eine zusätzliche Verbesserung lässt sich durch ein darauf aufbauendes präventives Wartungskonzept erzielen. Die jeweilige Diagnosegüte wird hierbei ein limitierender Faktor sein und bei Unterschreitung eines Mindestmaßes den Vorteil der präventiven Maßnahmen zur Vermeidung von Folgefehlern und Störungen des Betriebes kompensieren. Eine Untersuchung des benötigten Mindestmaßes wurde hier weder für Diagnose noch für Prognose durchgeführt, da die absoluten Zahlenwerte szenariospezifisch sind und der Fokus der Arbeit auf dem Nachweis der Leitungsfähigkeit von Prognose liegt. Die vorgestellte Simulationsumgebung bietet jedoch die Möglichkeit entsprechende Anforderungen für Diagnose & Prognose aus der PBC-Risikoanalyse herzu-leiten.

Mittels der Potentialanalyse für einen prädiktiven CBM-Ansatz lässt sich nachweisen, dass der operationelle Gewinn in Form von reduziertem Wartungsaufwand, erhöhter Verfügbarkeit und einer verbesserten Kontrolle des Risikos für PBC-Konzepte eine wesentliche Steigerung gegenüber dem korrektiven und präventiven Ansatz darstellt. Die gewonnenen Erkenntnisse zeigen deutlich den Nutzen der Prognose auf. Bei einer Investition in die Entwicklung eines Zustandsüberwachungssystems sollte somit eine übergeordnete Zielsetzung die Implementierung eines auf Fehlerprognose aufbauenden prädiktiven Instandhaltungskonzeptes sein.

Möglichkeiten für weiterführende Arbeiten bieten sich durch die Erweiterung des MMDL zu einer ereignisbasierten Simulationsumgebung. Ähnlich wie bei der Systecon Suite könnte die Zielsetzung hier sein, eine Umgebung zur Bestimmung eines gemittelten Wertes auf Segmentebene zu erhalten und durch die zusätzliche Monte-Carlo Simulation eine detailliertere Zeitreihenanalyse zu ermöglichen. Aufbauend auf den getroffenen Annahmen zur Handhabung der einzelnen Fehlerfälle und Wartungsstrategien kann die hier vorgestellte Umgebung entsprechend angepasst werden. Des Wei-

teren haben die Untersuchungen gezeigt, dass die Systemsimulation mit mehreren Segmenten im Missionsverbund Abweichungen gegenüber den Ergebnissen der Systecon Suite aufweist. Somit sollte zur weiterführenden Nutzung des MMDL eine Umgebung entwickelt werden, um ausgehend von den Ergebnissen auf Segmentebene auch für komplexe Missionsszenarien eine zuverlässige Simulation der erreichbaren Leistungsparameter zu ermöglichen.

4. Modellbasierte Systemidentifikation

In diesem Abschnitt wird die Implementierung der modellbasierten Systemidentifikation mit dem kombinierten Ansatz der *Genetischen Programmierung* und des *Unscented Kalman Filters* (GP-UKF) dargestellt. Zunächst werden Grundlagen der Systemidentifikation und modellbasierter Ansätze erläutert. Die Maßnahmen zur Realisierung eines integrierten Ansatzes zur modellbasierten Systemidentifikation werden aus gängigen Konzepten zur Auslegung von adaptiven Filtern hergeleitet und anhand eines Beispiels nachgewiesen. Voraussetzung hierfür waren Vorarbeiten zur Entwicklung der *Genetischen Programmierung*, ausgewählte Implementierungsformen des UKFs und validierte Kriterien zur Konsistenzprüfungen für eine Auslegung von rekursiven bayesschen Schätzverfahren.

4.1. Ansatz zur Implementierung

Die Systemidentifikation im Allgemeinen beschäftigt sich mit der Aufgabe aus einem beobachteten Input- / Output-Verhältnis Rückschlüsse über das zugrunde liegende Systemmodell zu ziehen.

Nach [70] besteht der Prozess zur Systemidentifikation aus drei Phasen:

- 1) Aufbereitung der Daten
- 2) Vorgabe von geeigneten Modellkandidaten
- 3) Bewertung von ausgewählten Kriterien zur Modellauswahl

Zur Auswertung der Bewertungskriterien gehört üblicherweise auch ein Validierungsschritt, um die Allgemeingültigkeit des identifizierten Systemmodells nachzuweisen. Hierzu wird das Modell mit bis dahin nicht genutzten Datensätzen getestet und das Ergebnis mit in die Bewertung einbezogen.

Das zu identifizierende System ist durch das Verhältnis der Eingangs- und Ausgangsgrößen charakterisiert [70]:




Abbildung 26: System mit Eingang u , Ausgang y , bekannter Störung v und unbekannter Störung w

Zusätzliche Störgrößen beeinflussen das Verhalten am Systemausgang. Messbare Störgrößen können bei der Systemidentifikation berücksichtigt werden, während das Verhältnis zwischen den beobachtbaren und nicht beobachtbaren Größen mitunter ein Maß für die erreichbare Qualität des identifizierten Modells ist. Im Gegensatz dazu erfordert ein modellbasierter Ansatz ausreichend Kenntnis über das System, um alle relevanten Eigenschaften durch eine geeignete Modellstruktur abzubilden. Für echtzeitbasierte Anwendungen dient das Modell dazu, anhand der Vorgabe von

Eingangs- und Ausgangsgrößen und dem Vergleich mit einem erwarteten Verhalten, Rückschlüsse über den Systemzustand, bzw. den Einfluss von nichtmessbaren Störgrößen zu treffen [71]:

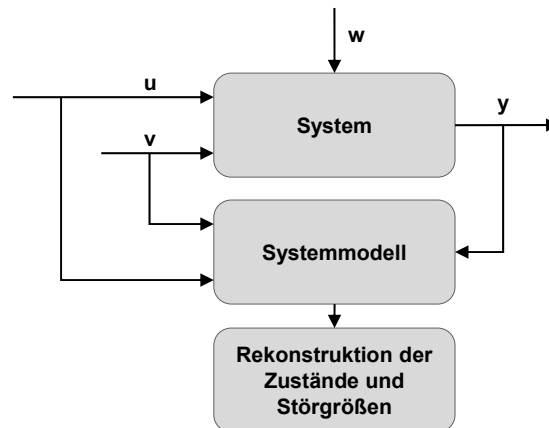


Abbildung 27: Modellbasierte Störgrößenidentifikation

Für nicht-echtzeitbasierte Anwendungen kann das Systemmodell auch genutzt werden, um unter Vorgabe von Nutzungsprofilen, zukünftige Modellzustände abzuschätzen.

Die Zielsetzung der Arbeit ist die Entwicklung eines Verfahrens zur Identifikation eines Modells für Degradierungsprozesse unter Berücksichtigung von nicht messbaren Störgrößen. Der Begriff „Modellbasierte Systemidentifikation“ wird an dieser Stelle eingeführt, da der untersuchte Ansatz zur Systemidentifikation einen modellbasierten Ansatz als integralen Bestandteil der Lösungsfindung verwendet:

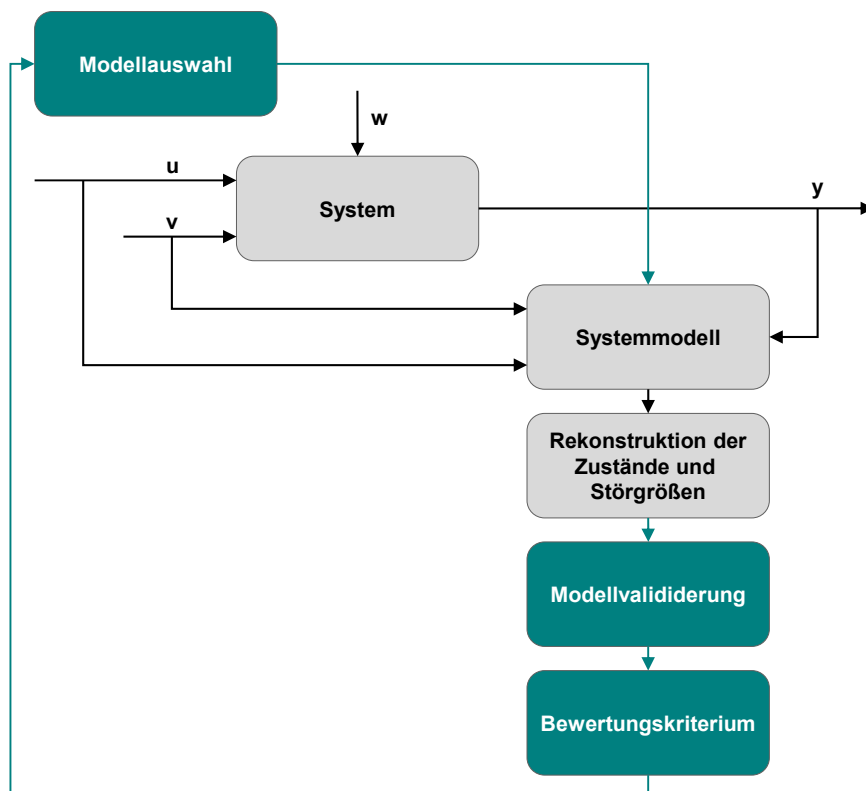


Abbildung 28: Modellbasierte Systemidentifikation

Die Systemidentifikation wurde mittels der *Genetischen Programmierung* umgesetzt. Hierbei werden die Kandidaten zur Modellauswahl iterativ bestimmt und konvergieren für ein geeignetes Bewertungskriterium gegen eine optimierte Lösung. Der modellbasierte Anteil zur Rekonstruktion der Störgrößen verwendet ein nichtlineares rekursives bayessches Filter, um auch nichtlineare Systemmodelle mit komplexen Modellstrukturen handhaben zu können. Die theoretischen Grundlagen für diese beiden Elemente werden im Folgenden kurz erläutert.

4.2. Genetische Programmierung

Die *Genetische Programmierung* gehört zur Klasse der evolutionären Rechenprozesse, welche mittels Prinzipien aus der Evolutionstheorie heuristische Probleme lösen. Hierbei werden im Gegensatz zu anderen evolutionären Ansätzen (wie z.B. *Genetische Algorithmen* [72]) keine Parameterwerte identifiziert, sondern der Versuch unternommen, ein durch ein beobachtetes Input- / Output-Verhalten charakterisiertes System durch eine logische Abbildung darzustellen. Diese Abbildungsform kann von einer einfachen mathematischen Struktur [73] bis hin zu einem komplexen Computerprogramm reichen [74]. Die Art der Lösung wird durch die zur Verfügung gestellte Bibliothek bestimmt. Hier werden die Elemente zur Lösungsfindung unabhängig voneinander definiert und mit dem Ziel ein vordefiniertes Kriterium (Fitness) zu optimieren während der Systemidentifikation durch genetische Operationen miteinander kombiniert (s. Abbildung 29). Die Fitnessfunktion zur Bewertung der Individuen kann beliebig gestaltet sein um die gewünschte Lösung zu erhalten.

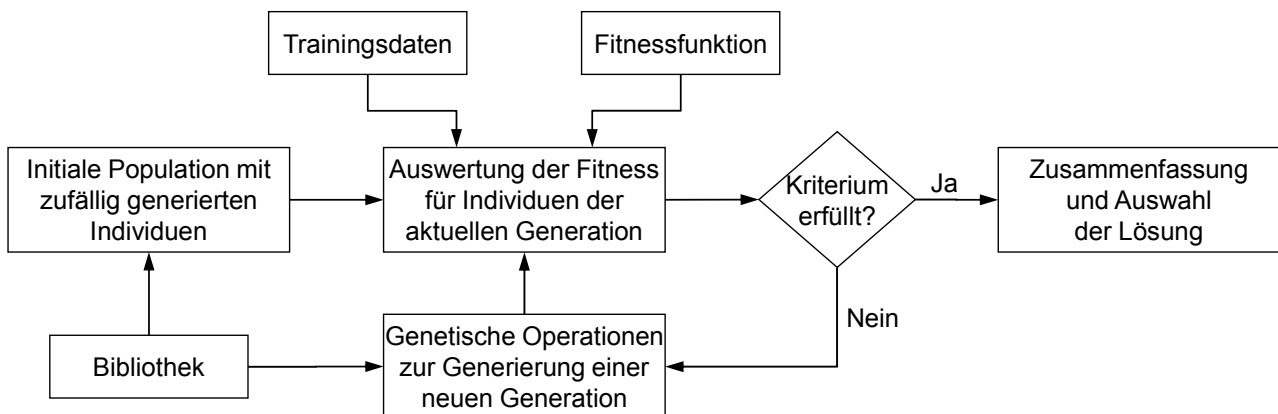


Abbildung 29: Heuristische Lösungsfindung mit *Genetischer Programmierung*

Die Identifikation verläuft über mehrere Generationen, die jeweils von unterschiedlichen Individuen gebildet werden, von denen jedes einzelne eine mögliche Lösung des Problems repräsentiert. Ausgehend von einer Initialgeneration, mit aus der vorgegebenen Bibliothek zufällig erzeugten Individuen, erfolgt nach der Bestimmung der Fitness jedes Individuums die Generierung einer Folgegeneration. Die Individuen der Folgegeneration basieren auf ausgewählten Elementen der Ausgangsgeneration. Die Wahrscheinlichkeit zur Auswahl eines Individuums aus der Ausgangsgeneration wird



aus der jeweiligen Fitness abgeleitet. Durch diesen Prozess der sogenannten „*fitnessproportionalen Reproduktion*“ wird die durchschnittliche Fitness der Gesamtpopulation über die Generationen hinweg kontinuierlich verbessert. Um die Lösung möglichst einfach zu halten, wird die Komplexität der Individuen mit in die Fitnessbestimmung einbezogen, bzw. bei gleicher Fitness das Individuum mit der einfacheren Abbildung bevorzugt [55]. Die Individuen der Folgegeneration werden aus den Individuen der Ausgangsgeneration mittels genetischen Operatoren erzeugt. Die möglichen genetischen Operationen sind „*Mutation*“, „*Crossover*“ und „*Direct Takeover*“ (s. Abbildung 30). Die Auswahl und Anwendung der Operatoren auf die Individuen wird anhand von gleichverteilten Wahrscheinlichkeiten durchgeführt. Der Lernprozess wird beendet wenn entweder die vorgegebene Anzahl an Generationen durchlaufen oder ein Abbruchkriterium erfüllt ist. Die Qualität der Lösung steigt hierbei mit dem Umfang der Bibliothek, der Anzahl der Individuen pro Generation und der Maximalanzahl an Generationen.

Mathematische Formulierung:



$$f(x) = 3 \cdot (x_1 + x_2)$$

$$g(x) = \frac{x_1}{2} - x_2$$



(a) Genetische Formulierung:



(b) Beispiel für Mutation:



(c) Beispiel für Crossover:



(d) Beispiel für Direct Takeover:





Abbildung 30: Für die Systemidentifikation verwendete Genetische Operatoren der Genetischen Programmierung: (a) \rightarrow (b): *Mutation*, (b) \rightarrow (c): *Crossover*, (c) \rightarrow (d): *Takeover*

Die ersten Ansätze und theoretischen Grundlagen für die *Genetische Programmierung* sind 1992 für die automatische Generierung von Computerprogrammen veröffentlicht worden. Seitdem wurden vielfältige Varianten erfolgreich getestet. Eine Erweiterung der in [74] beschriebenen Vorgehensweise stellt die „*Multi-Gene Regression*“ dar, bei der ein Individuum aus mehreren Genen besteht, die über eine lineare Operation miteinander verknüpft werden:

$$y(u) = a_1 \cdot g_1(u) + \dots + a_n \cdot g_n(u) \quad (6.1)$$

Hierbei repräsentiert $g_i(u)$ jeweils ein einzelnes Gen und die zugehörigen Parameter a_i müssen während der Systemidentifikation durch ein geeignetes Verfahren bestimmt werden. Die Bewertung des Individuums erfolgt anhand des resultierenden Ausgabewertes $y(u)$ im Vergleich zum beobachteten Systemausgabewert und erfordert somit das alle Teilgene in Kombination eine hinreichend genaue Lösung ermöglichen. Nach [73] lassen sich hiermit bei komplexen Aufgaben bessere Ergebnisse als mit nur einem einzelnen Gen pro Individuum erzielen.

Für weitere Details bzgl. der Implementierung sei an dieser Stelle auf [74] und weiterführende Arbeiten wie etwa [75], [76] verwiesen. Die verwendete Implementierungsform ist in [Anhang A](#) beispielhaft angegeben.

4.3. Rekursive Bayessche Schätzverfahren

Die rekursive Bestimmung einer unbekannten Modellgröße x anhand der Auswertung der vorhandenen Eingangsgrößen u und Messwerte y für alle verfügbaren Zeitschritte wird als Filterung bezeichnet [77]. Die deswegen auch als Filter bezeichneten Schätzer erfordern als Grundlage die Abbildung der Modellstruktur im Zustandsraum, wobei die gesuchte Modellgröße als zeitvariante Zufallsvariable angenommen wird:




Abbildung 31: Zustandsraum mit Prozessmodell $f(u, v, x)$ und Beobachtermodell $h(u, w, x)$

Das Modell im Zustandsraum ist durch das Prozessmodell $f(u, v, x)$, das Beobachtermodell $h(u, w, x)$ sowie die Kovarianzmatrizen für die Modellunsicherheiten v und Messungenauigkeiten w vollständig definiert.

Durch die Abbildung der gesuchten Modellgröße als Zufallsvariable ergibt sich für die Filterung eine bayessche Schätz Aufgabe. Die rekursive Implementierung besteht in der Bestimmung der Dichtefunktion $p(x_k)$ für die gesuchte zeitvariante Modellgröße x_k unter Ausnutzung der verfügbaren Messwerte $y_{1:k}$:

$$p(x_k | y_{1:k}) = \frac{p(y_k | x_k) \cdot p(x_k | y_{1:k-1})}{p(y_k | y_{1:k-1})} \quad (6.2)$$

Eine ausführliche Herleitung und Diskussion der einzelnen Terme und Schritte ist in [77] zu finden. Die in (6.2) enthaltenen stochastischen Integrale können nur für lineare Systeme mit additiven, normalverteilten Störgrößen gelöst werden. Die optimale Lösung als Minimalvarianz-Schätzer aus der Gruppe der gaußschen Approximationen hierfür liefert das Kalman Filter. Ausgehend von der

Implementierung für lineare Systeme sind verschiedene Formen für nichtlineare Schätzaufgaben entwickelt worden. Sequenzielle Monte-Carlo Simulationen und Verfahren zur numerischen Integration bieten weitere Ansätze, die eine Annäherung an die exakte Lösung darstellen [78].

Die Aufgabe einer rekursiven bayesschen Schätzung durch gaußsche Approximation besteht in der Bestimmung der ersten beiden statistischen Momente der gesuchten Modellgrößen. Hierzu wird mittels den Filtergleichungen zunächst die a-priori-Schätzung der Verteilung $p(x_k|y_{1:k})$ aufgestellt, die unter Berücksichtigung der verfügbaren Messgrößen im nachfolgenden Korrekturschritt zur a-posteriori Schätzung mit minimierter Varianz des Schätzfehlers korrigiert wird [78]. Je nach zeitlichem Versatz zwischen Schätz- und Messgrößen ($\tau = k_{\text{Schätz}} - k_{\text{Mess}}$), dient die Schätzung zur Filterung mit Echtzeitfähigkeit ($\tau = 0$), Prädiktion von Modellgrößen ohne Messwertkorrektur ($\tau > 0$) oder Signalglättung zur Bereinigung von Störungen und Modellfehlern ($\tau < 0$) [77].

Die Filterung kann hierbei auf die Bestimmung der Modellzustände (Zustandsschätzer), Parameter des Prozessmodells (Parameterschätzer) oder Kompensation von Störungen auf den Eingangs- und Ausgangsgrößen (Signalaufbereitung) ausgelegt sein. Die Zustandsschätzung zielt auf die Bestimmung von zeitvarianten Modellgrößen ab, während die Parameterschätzung von konstanten Modellparametern ausgeht. Als Sonderfall der Parameterschätzung gilt auch die Bestimmung von langsam variierenden Parameterwerten. Während ein Prozessmodell zur Abbildung der Zustandsänderung auch einen linearen Charakter haben kann, weist ein Modellparameter üblicherweise einen multiplikativen Beitrag zum Systemmodell auf. Je nach Aufgabenstellung ist somit eine lineare oder nichtlineare Filterauslegung erforderlich:

Prozess	Beobachtung	Störgrößen	Schätzaufgabe	Filter
Linear	Linear	Additiv	Signalaufbereitung	Linear
			Zustandsschätzung	
			Parameterschätzung	
		Multiplikativ	Signalaufbereitung	Nichtlinear
			Zustandsschätzung	
			Parameterschätzung	
Prozessmodell und / oder Beobachtermodell nichtlinear		Additiv oder Multiplikativ	Signalaufbereitung	
			Zustandsschätzung	
			Parameterschätzung	

Tabelle 8: Klassifikation zur Filterauslegung entsprechend Schätzaufgabe

Das LKF wurde 1960 als optimaler Zustandsschätzer für lineare Systeme eingeführt [79]. Eine Erweiterung für nichtlineare Probleme stellt das EKF dar [80]. Es verwendet partielle Ableitungen der Modellgleichungen nach den gesuchten Modellgrößen um diese zu linearisieren und so bei entspre-

chender Schrittweite auch mittels des LKF-Algorithmus nichtlineare Gleichungssysteme lösen zu können. Durch die Notwendigkeit zur Linearisierung und damit der Interpolation zwischen zwei Filterschritten, ist die Stabilität des Filters durch die verwendete Schrittweite begrenzt. Zusätzlich erfordert die Herleitung der Ableitungen einen entsprechenden Rechenaufwand, ist für harte Nichtlinearitäten nur bedingt geeignet und weist allgemein eine durch den Grad der Linearisierung bedingten Fehler auf. Das UKF ist eine Optimierung des EKF um diese Probleme zu vermeiden. Es verwendet anstelle der Linearisierung die „*Unscented Transformation*“ (sowie die „*Scaled Unscented Transformation*“ als Weiterentwicklung zur besseren Berücksichtigung höherer statistischer Momente) [81], bei der die nichtlineare Zustandsänderung durch die Anwendung der Modellgleichungen auf einen Satz an Sigma-Punkten, die den Mittelwert und die Varianz der ursprünglichen Verteilung der Modellgrößen widerspiegeln, abgebildet wird [82]. Die Klasse der sequenziellen Monte-Carlo Simulationen verwendet einzelne Punktlösungen, die mittels den Modellgleichungen propagiert werden, um eine pseudo-empirische Annäherung von $p(x_k|y_{1:k})$ zu ermöglichen [83]. Die verschiedenen Implementierungsformen der Partikelfilter sind die am häufigsten verwendeten Ansätze aus diesem Bereich [84], [85].

Das hier untersuchte Verfahren geht von normalverteilten, additiven Störgrößen aus und zielt auf eine Schätzaufgabe mit wahlweise nichtlinearen Prozess- und Beobachtermodellen ab. Um diesen Anforderungen gerecht zu werden und den Bedarf an Rechenleistung minimal zu halten, ist das UKF verwendet worden.

Für eine Diskussion der erforderlichen Randbedingungen und Vorgehensweisen zur Implementierung sei auf [77], [78] und für die Filtergleichungen auf [Anhang A](#) verwiesen.

4.4. Vorgehensweise für die modellbasierte Systemidentifikation

Zur Integration des UKFs in den Prozess der Systemidentifikation sind neben der Filterauslegung auch geeignete Kriterien zur Ergebnisbewertung zu definieren. Für eine reine Systemidentifikation ohne modellbasierten Anteil sind hierfür Aussagen über den mittleren Modellfehler und die Komplexität der benötigten Modelle hinreichend. Für den Ansatz der modellbasierten Systemidentifikation ist zusätzlich zur Modellgleichung auch die Filterauslegung zu bewerten. Hierfür sind entsprechende Bewertungskriterien aus dem Bereich der Theorie zur Auslegung von adaptiven Filtern aufgestellt worden. Des Weiteren ist eine geeignete Filterstruktur für die Schätzaufgabe auszuwählen, um eine vollständige Modellierung der in § 4.3 beschriebenen Zustandsraumdarstellung unter Berücksichtigung von nicht messbaren Störgrößen zu ermöglichen. Mögliche Vorgehensweisen zur Filterauslegung werden zunächst theoretisch betrachtet und dann anhand eines Beispiels bewertet, um die Auswahl eines geeigneten Ansatzes für die Implementierung der modellbasierten Systemidentifikation zu unterstützen.

4.4.1. Genetische Programmierung mit integriertem Unscented Kalman Filter

Das UKF dient in dem untersuchten Ansatz als Zustandsschätzer, um mittels eines von der *Genetischen Programmierung* hergeleiteten Systemmodells die Dynamik des den Trainingsdaten zugrunde liegenden Prozesses sowie den Einfluss enthaltener Störgrößen ξ abzubilden. Die Filtergleichungen entsprechen den Ergebnissen aus der *Genetischen Programmierung* und die Bewertung der Systemidentifikation wird aus der Qualität der gefilterten Größen und dem Ergebnis der Modellvalidierung abgeleitet:

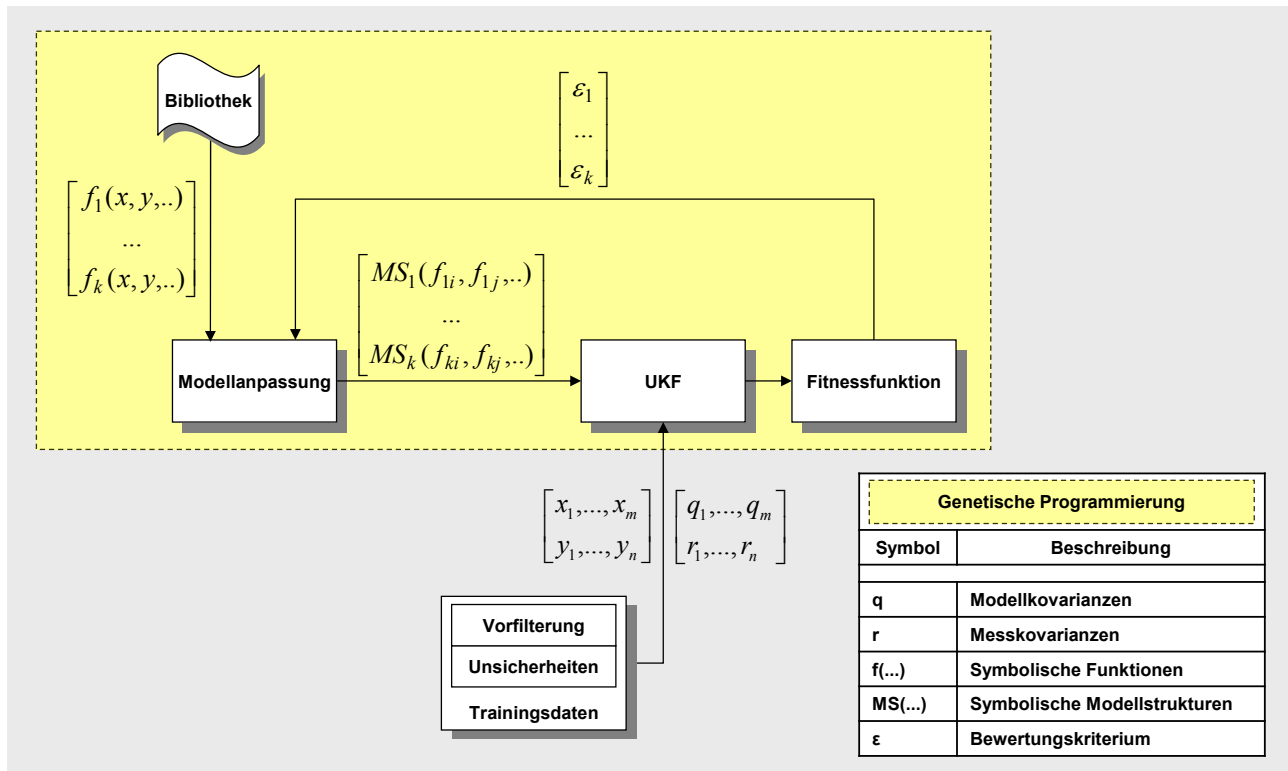


Abbildung 32: Konzept für modellbasierte Systemidentifikation

Die gesuchten Störgrößen können erst nach Kenntnis eines geeigneten Prozessmodells mittels der Zustandsschätzung durch das UKF bestimmt werden, weswegen für diese Anteile durch die *Genetische Programmierung* kein explizites Modell bestimmt werden kann. Ohne Kenntnis eines vollständigen Systemmodells lassen sich dynamische Prozesse durch einen Random-Walk-Ansatz mit geeigneter Parametrisierung des Filters abbilden. Um die Schätzaufgabe unter Berücksichtigung eines Systemmodells für die Modellzustände x und eines Random-Walk Anteils für die Störgrößen ξ zu beschreiben, können Ansätze aus dem Bereich der Parameter- und Zustandsschätzung verwendet werden [78], [86], [87]:

- Parameterschätzung
- Kombinierte Parameter- und Zustandsschätzung
- Getrennte Parameter- und Zustandsschätzung

Bei diesen Ansätzen werden die Parameteranteile üblicherweise als konstant oder langsam variierend angenommen. Für die gesuchten Störgrößen soll in Abhängigkeit vom Trainingsdatensatz für die Systemidentifikation eine beliebige Dynamik zugelassen werden. Hierfür wird der Parameteranteil der genannten Ansätze bei den weiteren Betrachtungen durch einen zeitvarianten Zustandsvektor ξ ersetzt, dessen rekursive Bestimmung dann der angestrebten Störgrößenidentifikation entspricht.

Die reine Parameterschätzung berücksichtigt keine explizite Darstellung des Prozessmodells, weswegen dieser Ansatz hier nicht weiter diskutiert wird. Bei einer Interpretation des Parameteranteils der Schätzaufgabe als zeitvariante Zustände ξ ohne explizites Systemmodell in Kombination mit einem bekannten Modellanteil für weitere Systemzustände x , bieten sich als Implementierungsformen des modellbasierten Anteils somit die kombinierte Parameter- und Zustandsschätzung, bzw. getrennte Parameter- und Zustandsschätzung an.

Für die genannten Ansätze werden im Folgenden die Zustandsraumdarstellungen und Voraussetzungen zur Anwendbarkeit näher erläutert. Des Weiteren wird ein ausgewähltes Beispiel verwendet, um die Fähigkeit zu bewerten, den Verlauf nicht messbarer Modellgrößen ohne Kenntnis des vollständigen Prozessmodells anhand der vorhandenen Messreihen zu rekonstruieren. Als Bewertungskriterium ist jeweils der mittlere quadratische Fehler zwischen den wahren und geschätzten Größen verwendet worden.

Als Grundlage für den Vergleich der beiden Verfahren wurde folgendes Zustandsraummodell verwendet:

$$\begin{aligned}x_k &= 0,6 \cdot u_{k-1} + \sqrt{\xi_{k-1} \cdot x_{k-1}} + v_{k-1} \\ y_k &= 2 \cdot x_k + 0,5 \cdot u_k + w_k\end{aligned}$$

mit:

- u_k = Normalverteilte Zufallsvariable ($\mu_u = 1$; $\sigma_u^2 = 10^{-2}$)
- ξ_k = Logarithmisch Normalverteilte Zufallsvariable ($\mu_\xi = 2,5$; $\sigma_\xi^2 = 10^{-1}$)
- v_k = Normalverteilte Zufallsvariable ($\mu_v = 0$; $\sigma_v^2 = 10^{-2}$)
- w_k = Normalverteilte Zufallsvariable ($\mu_w = 0$; $\sigma_w^2 = 10^{-2}$)

Für die Dynamik der gesuchten Störgröße, die durch den Zustand ξ_k abgebildet wird, ist kein Prozessmodell vorhanden und diese muss somit durch den Random-Walk Anteil beschrieben werden. Das Prozessrauschen Q_x und Messrauschen R_y (entsprechen hier σ_v^2 und σ_w^2) wurden jeweils als bekannt vorausgesetzt. Die Kovarianzen zur Beschreibung der Dynamik der Störgrößenschätzung Q_ξ wurden angepasst, um die Kriterien F1-F4 (s. § 4.4.2) möglichst exakt zu erfüllen.

4.4.1.1. Kombinierte Parameter- und Zustandsschätzung

Bei der kombinierten Parameter- und Zustandsschätzung („*Joint Estimation*“) wird die Dimension des Zustandsvektors um die Anzahl der zu bestimmenden Parameter erweitert. Diese Form der Implementierung eignet sich, wenn zwischen den Parametern und Zuständen eine Korrelation erwartet wird, da die Nebenelemente $P_{x\xi}$ und $P_{\xi x}$ der Kovarianzmatrix P , die bei der *Joint Estimation* mit geschätzt werden, diese Eigenschaft abbilden:

$$P_k = \begin{bmatrix} P_{x,k} & P_{x\xi,k} \\ P_{\xi x,k} & P_{\xi,k} \end{bmatrix} \quad (6.4)$$

Für die Auslegung als *Joint Estimation* ergibt sich folgendes Zustandsraummodell [87]:

$$\begin{aligned} \xi_k &= \xi_{k-1} + \zeta_k \\ x_k &= f(u_{k-1}, x_{k-1}, \xi_{k-1}) + v_{k-1} \\ y_k &= h(u_k, x_k) + w_k \end{aligned} \quad (6.5)$$

Die Dynamik der Parameterschätzung und damit auch die zulässige Dynamik der Störgröße ξ , wird durch das Prozessrauschen ζ abgebildet [88]. Die entsprechende Implementierung des UKFs für die *Joint Estimation* ist in Anhang A gegeben.

Die Ergebnisse der *Joint Estimation* für das gewählte Beispielsystem sind in Abbildung 33 dargestellt:




Abbildung 33: Ergebnis der Zustandsschätzung für kombinierte Parameter- und Zustandsschätzung:
(a) Schätzung für Modellzustand x , (b) Schätzung für Störgröße ξ

4.4.1.2. Getrennte Parameter- und Zustandsschätzung

Bei der getrennten Parameter- und Zustandsschätzung („*Dual Estimation*“) wird die statistische Abhängigkeit von Parametern und Zuständen vernachlässigt und jeweils ein eigenständiges Filter für die Parameter- und Zustandsschätzung verwendet. Somit werden die Nebenelemente $P_{x\xi}$ und $P_{\xi x}$ der Kovarianzmatrix P nicht berücksichtigt. Die Parameterschätzung geht hierbei von schrittweise konstanten Zustandsgrößen und die Zustandsschätzung von schrittweise konstanten Parameterwerten aus [78], [86]:

Parameterschätzung: $\xi_k = \xi_{k-1} + \varsigma_k$ (6.6)
 $y_k = h(u_k, f(u_{k-1}, x_{k-1}, \xi_k)) + w_k$

Zustandsschätzung: $x_k = f(u_{k-1}, x_{k-1}, \xi_{k-1}) + v_{k-1}$ (6.7)
 $y_k = h(u_k, x_k) + w_k$

Die verwendeten Algorithmen für die *Dual Estimation* entsprechen den Formen des UKFs zur Parameter- und Zustandsschätzung aus Anhang A. Die Kooperationsstrategie besteht in der schrittweisen Bereitstellung der Schätzgrößen aus dem Parameterschätzer an den Zustandsschätzer und entsprechend aus dem Zustandsschätzer an den Parameterschätzer.

Die Ergebnisse der *Dual Estimation* für das Beispielsystem sind in Abbildung 34 dargestellt:




Abbildung 34: Ergebnis der Zustandsschätzung für getrennte Parameter- und Zustandsschätzung: (a) Schätzung für Modellzustand x , (b) Schätzung für Störgröße ξ

4.4.1.3. Auswahl der Filterauslegung für die Störgrößenschätzung

Die Qualität der Schätzung für das Beispielsystem mittels der *Joint Estimation* und *Dual Estimation* ist anhand der Residuen für die beiden Schätzgrößen ξ und x in Abbildung 34 dargestellt:




Abbildung 35: Vergleich Schätzung für getrennte und kombinierte Parameter- und Zustandsschätzung anhand der Residuen: (a) Schätzfehler v_x für Zustand x , (b) Schätzfehler v_ξ für Zustand ξ

Beide Ansätze sind geeignet, um für das ausgewählte Beispielsystem sowohl den Verlauf des Modellzustandes x mit bekanntem Prozessmodell als auch der Störgröße ξ ohne Kenntnis des Prozessmodells hinreichend gut zu bestimmen.

Die Unterschiede in der Qualität der Schätzung zeigen keine signifikanten Unterschiede auf, die als Auswahlkriterium für eine Filterauslegung dienen könnten:

Filterauslegung	Schätzgröße	Mittlerer quadratischer Fehler
<i>Joint Estimation</i>	x	0,51
	ξ	1,6
<i>Dual Estimation</i>	x	0,65
	ξ	1,1

Tabelle 9: Bewertung der Filterauslegung zur Schätzung von ξ mit unbekanntem Prozessmodell

Nachdem für beide Auslegungsformen bei entsprechender Wahl von Q_ξ die Fähigkeit zur Schätzung von zeitvarianten Modellgrößen ohne Kenntnis des Prozessmodells nachgewiesen wurde, sind die Komplexität der Filterauslegung sowie das mögliche Einsatzspektrum als Auswahlkriterium für die Implementierung der modellbasierten Systemidentifikation verwendet worden. Hierfür ist die Auslegung als *Joint Estimation* zu bevorzugen, da für diese Variante des UKFs bei einem Mittelmaß an Komplexität das volle Einsatzspektrum als Parameter- und Zustandsschätzer ermöglicht wird. Nach [78] bietet diese Form der Implementierung hinsichtlich der Robustheit und Zuverlässigkeit für die Schätzaufgabe auch einen leichten Vorteil gegenüber der *Dual Estimation*. Diese Aussage konnte mit dem gewählten Beispiel zwar nicht bestätigt werden, jedoch ist der Betrieb von zwei unabhängigen UKFs und die Vernachlässigung einer möglichen Korrelation der Schätzgrößen x und ξ auch für eine vergleichbare Qualität der Schätzung ein Entscheidungskriterium die Auslegung als *Joint Estimation* zu bevorzugen.

4.4.2. Bewertungskriterien der modellbasierten Systemidentifikation

Das erste Kriterium zur Bewertung der Schätzung und damit implizit auch der Filterauslegung ist das quadratische Mittel ($RMSE_S$) der Schätzfehler der Messgrößen über alle Filterschritte:

$$\text{Kriterium F1:} \quad RMSE_S = \sqrt{\frac{\sum_{k=1}^N v_k^2}{N}} \quad (6.8)$$

$$\text{wobei:} \quad v_k = y_k - \hat{y}_k \quad (6.9)$$

$$\hat{y}_k = h(u_k, f(u_{k-1}, x_{k-1}, \hat{\xi}_{k-1})) \quad (6.10)$$

mit:

N = Anzahl der Filterschritte

Weitere Möglichkeiten zur Bewertung der Modellidentifikation bieten ausgewählte Konvergenzkriterien für die Schätzaufgabe.

Zur Konsistenzprüfung der Filterauslegung durch die *Genetische Programmierung* müssen folgende Kriterien erfüllt sein [89]:

- (1) Die Schätzfehler der internen Modellgrößen haben den Erwartungswert „Null“ und eine Kovarianz entsprechend den Filtervorgaben.
- (2) Die Schätzfehler der Messgrößen müssen die gleichen Bedingungen erfüllen.
- (3) Die Verteilung der Schätzfehler der Messgrößen ist weiß (Erwartungswert „Null“, nicht korreliert und konstante Varianz).

Nach [77] können diese Konvergenzkriterien entweder für eine Implementierung als Zustandsschätzer, Parameterschätzer oder duale Schätzung (simultane Schätzung von Zuständen und Parametern) zur Bewertung der Filterauslegung verwendet werden. Da die wahren Werte der geschätzten Modellgrößen durch die Modellstruktur beeinflusst werden und somit während der Identifikationsphase nicht bekannt sind, kann (1) nicht überprüft werden. Die Systemidentifikation wird für einen konstanten Datensatz durchgeführt (Echtzeitanwendung), weswegen keine Monte-Carlo Simulationen zur Konsistenzbewertung durchgeführt werden können. Nach [89] kann die Filterkonsistenz für Echtzeitanwendungen mit (6.11) und (6.13) bewertet werden. Daraus abgeleitet ergeben sich zusätzliche Kriterien zur Bewertung einer Filterauslegung [90]:

$$\varepsilon_v = \frac{1}{N} \cdot \sum_{n=1}^N v(n)^T \cdot P_y(n)^{-1} \cdot v(n) \quad (6.11)$$

$$\text{Kriterium F2:} \quad \frac{\varepsilon_v}{n_y} \approx 1 \quad (6.12)$$

$$\rho'(\tau) = \sum_{n=1}^{N-\tau} v(n)^T \cdot v(n+\tau) \cdot \left[\sum_{n=1}^N v(n)^T \cdot v(n) \cdot \sum_{n=1}^{N-\tau} v(n+\tau)^T \cdot v(n+\tau) \right]^{-0,5} \quad (6.13)$$

$$\text{Kriterium F3:} \quad E[\rho'] = \frac{\sum_{k=1}^K \rho'(\tau)}{K} \approx 0 \quad (6.14)$$

$$\text{Kriterium F4:} \quad \sigma^2_{\rho'} = \frac{1}{K} \cdot \sum_{k=1}^K (\rho'(\tau) - E[\rho'])^2 \approx \frac{1}{N} \quad (6.15)$$

mit:

K = Versatz der Autokorrelation ρ'

n_y = Anzahl der unabhängigen Messgrößen

Der mit (6.11) bestimmte Parameter ε_v wird auch als „*Time Averaged Normalized Innovation Square*“ bezeichnet. Für eine konsistente Filterauslegung besitzt ε_v eine χ^2 -Verteilung mit n_y Freiheitsgraden [89]. Aus dieser Annahme lässt sich (6.12) ableiten. Das Kriterium F2 liefert hinsichtlich der Konsistenzbewertung die wichtigste Aussage, indem es beurteilt, ob die Schätzung der Modellaus-

gabewerte einen systematischen Fehler aufweist, der bei längeren Schätzaufgaben zur Divergenz des Filters führen kann und ob die geschätzte Fehlerkovarianz den Merkmalen der beobachteten Abweichung zwischen den Filterausgabewerten und Messwerten entspricht.

Für weißes Rauschen mit unkorrelierten Größen (entspricht Forderung 3) liefert die Analyse der Autokorrelation durch ρ' bei hinreichend großer Anzahl an Messwerten für alle Werte $\tau > 0$ einen Erwartungswert von ≈ 0 und eine Varianz von $\approx 1/N$, woraus sich (6.14) und (6.15) ergeben.

Üblicherweise wird die Gültigkeit der Hypothesen für Kriterium F2-F4 mit einem Signifikanztest unter Berücksichtigung einer χ^2 -Verteilung für ε_v , bzw. der Standardnormalverteilung für ρ' nachgewiesen [77], [89]. Für die Implementierung im Rahmen der modellbasierten Systemidentifikation wird jedoch die Herleitung eines quantitativen Kriteriums zur Bewertung der Modellauswahl benötigt. Somit dienen (6.12), (6.14) und (6.15) für die *Genetische Programmierung* als Kriterien, um bei vorgegebenen Kovarianzmatrizen Q_x , Q_ξ und R_y die Herleitung einer Modellstruktur für eine konsistente Filterauslegung zu unterstützen.

Für eine normierte Implementierung von Kriterium F2 und F4 wird anstelle des errechneten Wertes die relative prozentuale Abweichung vom geforderten Wert als Bewertungskriterium verwendet:

$$\nu_i = \frac{|x_i - P(x_i)|}{x_i} \cdot 100 \quad (6.16)$$

mit:

x_i = Ergebniswert Kriterium i

$P(x_i)$ = Geforderter Wert Kriterium i

Die Bewertung der Systemidentifikation erfolgt anhand eines gewichteten Mittelwertes der einzelnen Kriterien aus (6.8)-(6.16):

$$\mathcal{E} = \frac{\sum_{i=1}^S w_i \cdot \nu_i}{w_i} \quad (6.17)$$

mit:

S = Anzahl der verwendeten Bewertungskriterien

w_i = Gewichtung Bewertungskriterium i

ν_i = Erreichter Wert Bewertungskriterium i

Für das Prognosekonzept liefert die Modellvalidierung in Form einer Fehlerprognose für bekannte Verläufe zusätzliche Informationen zur Bewertung des jeweiligen Modells. Diese werden in § 5.3.1 näher erläutert.

4.4.3. Validierung der Bewertungskriterien

Zur Illustration der gewählten Konvergenzkriterien für Echtzeitanwendungen werden mit dem Beispielsystem aus § 4.4.1 und $N = 10000$ die Ergebnisse für eine Schätzung der beiden Zustände x und ξ analysiert. Die Varianzanteile für das Messrauschen (R_y) und den Systemzustand x (Q_x) werden als bekannt vorausgesetzt. Die Eignung der gewählten Kriterien zur Bewertung der Filterkonsistenz wird anhand eines variablen Q_ξ vorgenommen.

Der Wert für die Prozesskovarianz Q_ξ bestimmt einerseits die Dynamik andererseits aber auch die Güte der Schätzung für ξ durch den Random-Walk Prozess. Abhängig davon, ob die gewählten Kovarianzen Q_x , Q_ξ und R_y zu klein oder zu groß gewählt worden sind, spricht man von einer optimistischen oder pessimistischen Schätzung [77]. Diese Aussage wird bei der späteren Auswahl der Modellstrukturen durch die Systemidentifikation nicht berücksichtigt, könnte jedoch eingebracht werden, um zur Gewährleistung von ökonomisch- oder sicherheitsrelevanten Aspekten eine der möglichen Modellvarianten zu bevorzugen, wenn durch die *Genetische Programmierung* keine optimale Auslegung erzielt werden kann.

Für eine konsistente Schätzung wurde iterativ durch eine manuelle Optimierung der Filterparameter ein Wert von $Q_\xi = 0,65$ bestimmt. Für die Schätzaufgabe wurde die gewählte UKF Implementierungsform mit erweitertem Zustandsvektor entsprechend der kombinierten Parameter- und Zustandsschätzung aus Anhang A verwendet.

Für eine korrekte Parametrisierung des Filters erfüllen die gewählten Kriterien F2-F4 weitestgehend die geforderten Werte und weisen damit die Konsistenz der Filterauslegung nach (s. Abbildung 36). Der Schätzfehler, der als Grundlage für Kriterium F1 verwendet wird, liefert ohne Referenzwert keine zusätzlichen Informationen über die Qualität der Filterung. Die 95% Akzeptanzintervalle für die Analyse des Residuums v_y liegen nach (6.15) bei $\pm 0,0196$ ($\pm 2 \cdot \sigma_{Ref}$, mit der Standardnormalverteilung als Referenzverteilung). Somit kann die Annahme (3) (Residuum v_y erfüllt die genannten Kriterien für weißes Rauschen) bestätigt werden, wenn 95% aller Werte, die mit (6.13) berechnet werden, innerhalb dieses Akzeptanzintervalls liegen. Der erreichte Wert liegt jedoch nur bei 93,2%, was auf die Verwendung des Random-Walk-Ansatzes anstelle eines expliziten Prozessmodells für ξ zurück zu führen ist. Dieser Effekt lässt sich auch anhand des Kriteriums F4 beobachten, was eine leicht erhöhte Autokovarianz gegenüber dem theoretischen Wert nachweist. Die Wahl der Anfangswerte und Dynamik des Random-Walk-Ansatzes haben durch das dadurch bestimmte Einschwingverhalten zu Beginn der Schätzaufgabe zusätzlichen Einfluss auf die erreichbaren Werte der Kriterien F1-F4.

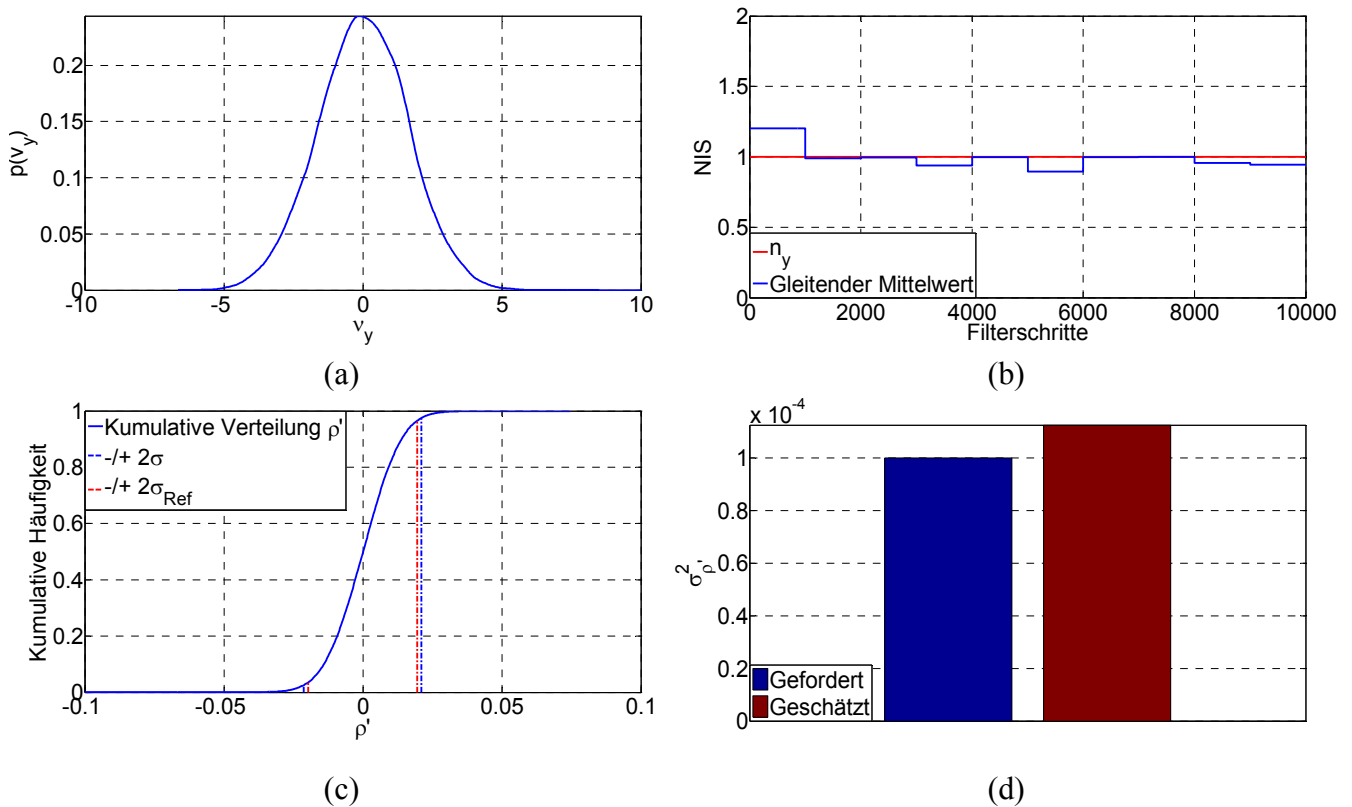


Abbildung 36: Konsistente Schätzung: (a) Dichteverteilung Kriterium F1, (b) Gleitender Mittelwert Kriterium F2 im Vergleich zu gefordertem Wert, (c) Kumulative Verteilung für Kriterium F3 mit empirischen und geforderten 95% Akzeptanzintervallen, (d) Kriterium F4

Zum Vergleich sind in [Abbildung 37](#) die Ergebnisse für eine inkonsistente Auslegung mit $Q_\xi = 10^{-3}$ dargestellt. Während der Schätzfehler keine eindeutige Unterscheidung zu Gunsten der konsistenten Auslegung zulässt, wird durch den Verlauf der anderen Kriterien die Abweichung von den geforderten Werten deutlich gemacht. Durch die zu geringe Varianz des Random-Walk kann die Dynamik der Schätzung nicht hinreichend gut abgebildet werden und das Kriterium F2 weist eine zu optimistische Filterauslegung mit $E[NIS] \gg n_y$ auf. Die Auswertung der Autokorrelation von v_y weist einen ähnlichen Effekt nach, indem für die inkonsistente Auslegung nur noch 90,8% aller Werte innerhalb des Akzeptanzintervalls liegen. Die Abweichung zwischen der geschätzten und der geforderten Autokovarianz ist ebenfalls höher als für die konsistente Auslegung. Eine entsprechende Betrachtung kann bei Bedarf auch für die Bewertung von Q_x oder R_y vorgenommen werden.

Zusammenfassend lässt sich anhand des gewählten Beispiels feststellen, dass die Analyse der Autokorrelation durch ρ' nur bedingt geeignet ist, um die korrekte Parametrisierung der Filterkovarianzen nachzuweisen. Das Kriterium F2 liefert einen besseren Indikator für die Schätzung der Modellkovarianzen. Dieses Ergebnis deckt sich mit den Aussagen in [89], wonach die Analyse der Schätzfehler für die Zustände und Messwerte bei der Filterauslegung eine größere Rolle spielt als die Autokorrelationsanalyse des Residuums. Dieses Ergebnis wird bei der Anpassung der Filterkovarianzen für den untersuchten GP-UKF-Ansatz berücksichtigt, indem der wesentliche Fokus während der

Systemidentifikation und einer Optimierung der Filterparametrisierung auf den Kriterien F1 und F2 liegen wird.

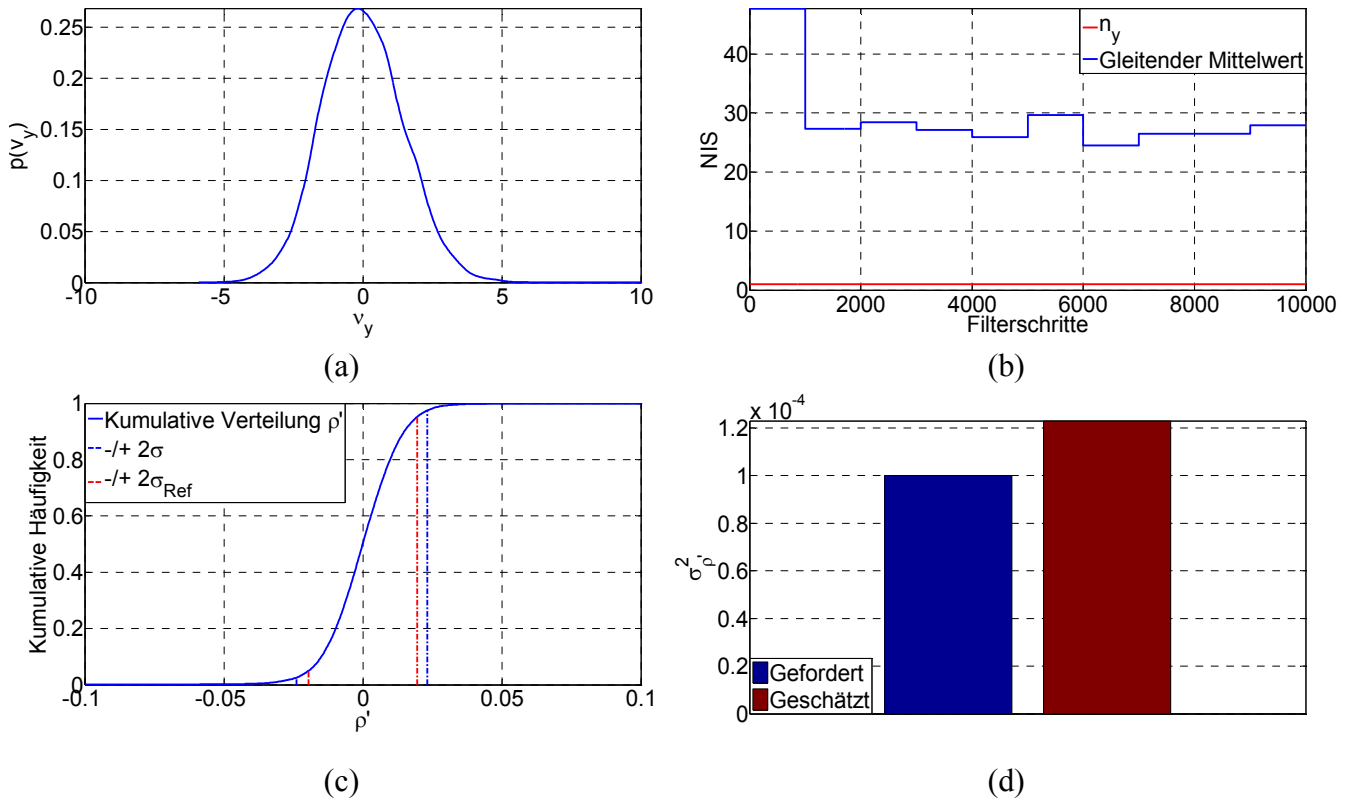


Abbildung 37: Inkonsistente Schätzung: (a) Dichteverteilung Kriterium F1, (b) Gleitender Mittelwert Kriterium F2 im Vergleich zu gefordertem Wert, (c) Kumulative Verteilung für Kriterium F3 mit empirischen und geforderten 95% Akzeptanzintervallen, (d) Kriterium F4

Die Zahlenwerte der Kriterien F1-F4 sind für beide Szenarien in [Tabelle 10](#) zusammengefasst:

Bewertungskriterium	Sollwert	Konsistente Schätzung	Inkonsistente Schätzung
Kriterium F1	0	1,61	1,81
Kriterium F2	1	0,98	29,15
Kriterium F3	0	-3,53e-5	-4,31e-6
Kriterium F4	10-4	1,12e-4	1,23e-4

Tabelle 10: Beispiel für Bewertung der Filterkonsistenz

Anhand der in § 4.4.1.3 und hier gezeigten Ergebnisse lassen sich folgende Aussagen bestätigen:

- (1) Die gewählte Implementierungsform des UKFs ist geeignet, um zeitvariante Modellzustände mit und ohne explizitem Prozessmodell zu bestimmen.
- (2) Die verwendeten Kriterien sind geeignet um die Filterkonsistenz in Echtzeit zu bewerten.

Diese Ergebnisse werden genutzt um die Implementierung der modellbasierten Systemidentifikation zu bestätigen. Zielsetzung hierbei ist, für ein bekanntes Verhalten von w_k , eine geeignete Mo-

dellstruktur für ein vorgegebenes v_k zu identifizieren. Der Wert von w_k wird als aus der Messreihenanalyse bekannt vorausgesetzt.

Durch die evolutionäre Entwicklung während der Iterationen der *Genetischen Programmierung* ist zwar nicht sichergestellt, dass die finale Modellstruktur alle Kriterien hinreichend erfüllt, jedoch ist gewährleistet, dass die Lösung kontinuierlich gegen ein Optimum strebt, was bei entsprechendem Umfang der Identifikationsaufgabe alle Kriterien näherungsweise erfüllen sollte.

4.5. Hybrider Ansatz für Modellbasierte Systemidentifikation

In diesem Abschnitt wird die Implementierung einer hybriden Filterstrategie für die modellbasierte Systemidentifikation erläutert. Die Motivation für den gewählten Ansatz entstammt den Vorarbeiten aus dem Bereich der hybriden bayesschen Filterung [91]. Zunächst werden die Grundlagen und ausgewählte Ansätze beschrieben, im Anschluss daran die daraus abgeleitete Implementierung für die *Genetische Programmierung* und darauf aufbauend die Anwendung für den untersuchten GP-UKF-Ansatz.

4.5.1. Hybride Ansätze für Bayessche Schätzverfahren

Hybride Schätzverfahren verwenden mehr als ein Referenzmodell um ein Problem zu beschreiben. Neben der Bestimmung der gesuchten Modellgrößen wird in jedem Filterschritt hierbei auch eine Kennzahl bestimmt, die ein Maß für die Eignung des jeweiligen Modells ist, das beobachtete Systemverhalten zu beschreiben. Der Begriff „*Hybride Schätzung*“ leitet sich aus dieser erweiterten Schätzaufgabe zur Bestimmung einer hybriden Zufallszahl ab. Die hybride Zufallszahl ist durch die Kombination der eigentlich gesuchten Modellgröße x und der Auswahl eines Modells m gegeben. Die hybride Schätzung zielt darauf ab, anhand der verfügbaren Messwerte y eine Dichtemassenfunktion für x zu bestimmen:

$$g(x, m | y) = f(x | m, y) \cdot \mu(m | y) \quad (6.18)$$


mit:

- $f(\cdot)$ = Wahrscheinlichkeitsdichtefunktion
- $\mu(\cdot)$ = Wahrscheinlichkeitsmassenfunktion
- $g(\cdot)$ = Dichtemassenfunktion

Die gesuchte Modellgröße x wird hierbei als kontinuierliche Zufallszahl angenommen, während die Möglichkeiten zur Modellauswahl m diskret über alle verfügbaren Modelle verteilt sind.

Eine hybride Schätzaufgabe würde in der rekursiven Bestimmung der einzelnen Wahrscheinlichkeitsdichtefunktionen und Wahrscheinlichkeitsmassenfunktionen bestehen, um daraus die gesuchte Dichtemassenfunktion $g(x, m | y)$ abzuleiten.

In [Abbildung 38](#) ist die resultierende Dichtemassenfunktion $g(x, m|y)$ für die Kombination von drei Wahrscheinlichkeitsdichtefunktionen $f_i(x|y)$ und Wahrscheinlichkeitsmassenfunktionen $\mu(m_i)$ dargestellt ($[E_1(x); E_2(x); E_3(x)] = [1; 3; 5]$; $[\sigma_1; \sigma_2; \sigma_3] = [1; 1,5; 0,75]$; $[\mu(m_1); \mu(m_2); \mu(m_3)] = [0,25; 0,45; 0,3]$):



[Abbildung 38](#): Dichte-Massenfunktion aus gewichteten Normalverteilungen

Für $g(x, m|y)$ sind hierbei neben der Varianz zur Abbildung von Unsicherheiten der Schätzaufgabe im Wesentlichen das „*Minimum Mean-Square Error*“ (MMSE) und „*Maximum a Posteriori*“ (MAP) Kriterium von Interesse [92]:

$$x^{MMSE} = E[x | y] \quad (6.19)$$

$$x^{MAP} = \arg \max_x \{g(x, m | y)\} \quad (6.20)$$

Das MMSE-Kriterium gibt den Schwerpunkt x^{MMSE} der Dichtemassenfunktion an, während durch x^{MAP} der Punkt beschrieben wird, der in einer diskreten Verteilung am Häufigsten auftreten würde. Nach [93] wird damit durch x^{MMSE} der durchschnittliche Schätzfehler minimiert, während x^{MAP} die Wahrscheinlichkeit zur Annäherung an den wahren Modellwert maximiert.

Hybride Ansätze eignen sich immer dann, wenn das Systemverhalten durch verschiedene Betriebszustände charakterisiert ist und ein einzelnes Modell nicht alle Zustände hinreichend genau abdecken kann. Bekannte Anwendungsgebiete sind z.B. die Navigation [92], [91], Fehlerdiagnose [77], [94] oder Sensordatenfusion [95].

Als „*Multiple Model*“ gelten diejenigen Ansätze, die nicht nur mehrere Referenzmodelle zur Auswahl haben, sondern während bestimmter Filterschritte auch mehr als ein Modell gleichzeitig verwenden, während bei „*Single Model*“ Konzepten nach einer Vorauswahl für jeden Filterschritt jeweils nur ein Modell verwendet wird [92].

Die beschriebene Unterscheidung in der Kooperationsstrategie ist in [Abbildung 39](#) anhand von zwei kooperierenden Modellen veranschaulicht:

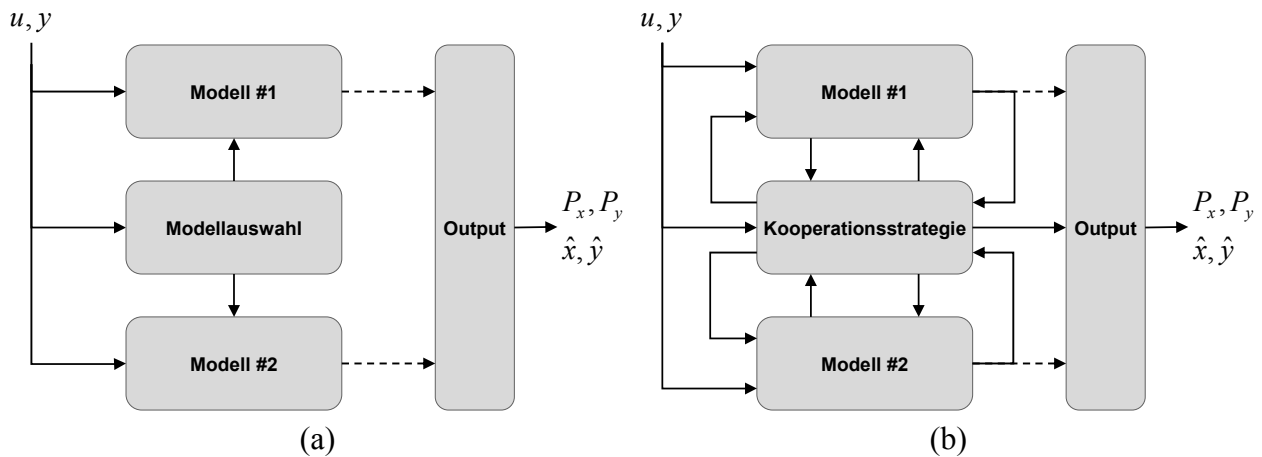


Abbildung 39: Hybride Filterkonzepte: (a) *Single Model*-Strategie, (b) *Multiple Model*-Strategie

Der wesentliche Nachteil einer *Single Model*-Strategie gegenüber den *Multiple Model*-Ansätzen besteht darin, dass Abweichungen von der Idealauswahl (keine absolute Übereinstimmung zwischen beobachteten Systemverhalten und dem ausgewählten Modell) nicht berücksichtigt werden. Somit wird ein Modell, das nur geringfügig bessere Eigenschaften als die anderen besitzt, als einzige Referenz genutzt, auch wenn es keine vollständige Abbildung des Systems ermöglicht.

Die multiple Modellauswahl wird bei den *Multiple Model*-Ansätzen berücksichtigt, indem alle Modellausgänge entsprechend der zugeordneten Modelleignung gewichtet und zu einem Ausgabewert fusioniert werden. Die Modellauswahl erfolgt nach der Filterung, womit der vorhandene Informationsgehalt zur Modellgewichtung vollständig genutzt wird.

Die *Multiple Model*-Ansätze untergliedern sich in drei Kategorien [92]:

1. *Autonomous Multiple Model* (AMM)
2. *Cooperating Multiple Model* (CMM)
3. *Variable Structure Multiple Model* (VSMM)

Die für das untersuchte Prognosekonzept relevanten Aspekte dieser Ansätze werden im Folgenden kurz erläutert.

4.5.1.1. Autonomous Multiple Model Schätzer

Die AMM bilden die Grundlage für die CMM und verwenden in vielen Teilbereichen der Schätzaufgabe dieselbe Vorgehensweise zur Filterkooperation. Bei den AMM rechnen die Modelle unabhängig voneinander mit den gleichen Messwerten und die Kooperationsstrategie besteht aus der Bereitstellung eines gewichteten Ausgabewertes aller Modelle.

Die Überlegenheit gegenüber den SMs besteht in der Nutzung aller verfügbaren Schätzwerte entsprechend der jeweiligen Eignung des zugrunde liegenden Modells anstelle von einem einzelnen Ausgabewert.

Grundlegende Annahmen für AMM sind [92]:

A1. Der wahre Systemzustand z_w ist zeitinvariant.

A2. Der wahre Systemzustand z_w besitzt zu jedem Zeitpunkt einen Zustandsraum Z , der zeitinvariant ist und dem Modellraum M der verwendeten Modelle entspricht.

Der Systemzustand z_w definiert hierbei den wahren Zustand, der durch die Modellauswahl beschrieben werden soll. Unter Einhaltung der Annahmen A1 & A2 konvergiert die Modellauswahl im Laufe einer Schätzaufgabe gegen z_w , so dass dieser letztendlich ausschließlich durch das entsprechende Modell m_w beschrieben wird. Die Bestimmung des Erwartungswertes und der Kovarianz erfolgt nach [92] für AMM durch (6.21) und (6.22):

$$\hat{x} = MMSE(x | y) = \sum_{i=1}^M \hat{x}_i \cdot \mu_i \quad (6.21)$$

$$P_x = MSE(x | y) = \sum_{i=1}^M \left[P_i + (\hat{x}_i - \hat{x}) \cdot (\hat{x}_i - \hat{x})^T \right] \cdot \mu_i \quad (6.22)$$

wobei:

$$\mu_i = \frac{\mu_{i,k|k-1} \cdot L_{i,k}}{\sum_{j=1}^M \mu_{j,k|k-1} \cdot L_{j,k}} \quad (6.23)$$

mit:

L = Likelihood abgeleitet aus Modellresiduum und zugehöriger Kovarianz

M = Anzahl der verwendeten Modelle

MSE = „Mean Square Error Matrix“ (entspricht Kovarianzmatrix der Schätzfehler)

Umfassende Studien für eine leistungsoptimierte Anwendung von AMMs haben zwei wesentliche Nachteile dieser Konzepte aufgezeigt [92], [96]:

1. Fehlerhafte oder verzögerte Auswahl der korrekten Modelle.
2. Nicht zu vernachlässigende Auswirkungen der fehlerhaften Modellauswahl auf die Ergebnisqualität.

Aus diesen Ergebnissen lässt sich ableiten, dass AMM bei häufigen Modellwechseln nur bedingt geeignet sind, da die Annahme A1 dann nicht erfüllt wird. Um auch diesen Anforderungen gerecht zu werden und den Ergebnisraum nicht auf eine finite Anzahl an Modellen zu beschränken, sind die CMM und VSMM entwickelt worden.

4.5.1.2. Cooperating Multiple Model Schätzer

Ansätze der zweiten Form, die CMM, nutzen eine erweiterte Kooperationsstrategie, die auch einen veränderlichen Systemzustand z und damit Modellwechsel zulassen. Somit wird Annahme A1 entsprechend zu B1 erweitert:

B1. Der wahre Systemzustand z_w folgt einem Markov-Prozess.

Die Vorgehensweisen zur Bestimmung der Schätzgrößen $MMSE(x|y)$ und $MSE(x|y)$ nach (6.21) und (6.22) sind unverändert gültig. Nach [92] sind die damit hergeleiteten Größen x^{MMSE} und x^{MAP} auch für eine zufällige Folge von z_1, \dots, z_k und für eine Abweichung von A2 geeignet um die resultierende Dichtemassenfunktion zu beschreiben. Eine Abweichung von A2 wird immer dann erwartet, wenn es im Modellraum M kein einziges Modell gibt, das den aktuellen Systemzustand z_k vollständig beschreiben kann und somit mehr als ein Modell gleichzeitig genutzt werden muss um das Ergebnis zu bilden.

Durch die Berücksichtigung der Modellwechsel hängt auch die Gewichtung eines jeden Modells von den vorhergehenden Filterschritten ab und erhöht damit die Anzahl der benötigten Schätzungen. Es wurden diverse Kooperationsstrategien entwickelt, um die mit der Anzahl der Filterschritte exponentiell zunehmende Komplexität der Schätz Aufgabe zu reduzieren. Die populärsten Varianten („Generalized Pseudo Bayesian 1-ter Ordnung“ - GPB1 und „Interacting Multiple Model“ - IMM) verwenden eine Transitionsmatrix H , um vor jedem Filterschritt die Modellgrößen x_i und P_{xi} aus dem letzten Filterschritt neu zu initialisieren [77]:

$$H = \begin{bmatrix} h_{11} & \dots & h_{n1} \\ \dots & \dots & \dots \\ h_{1n} & \dots & h_{nn} \end{bmatrix} \quad (6.24)$$

$$m_{i,k-1|k-1} = f(h_{ji}, m_{i,k-1}, m_{j,k-1}) \quad (6.25)$$

$$\bar{x}_{i,k-1|k-1} = f(\hat{x}_{i,k-1|k-1}, \hat{x}_{j,k-1|k-1}, m_{i,k-1}, m_{j,k-1}) \quad (6.26)$$

$$\bar{P}_{xi,k-1|k-1} = f(P_{xi,k-1}, P_{xj,k-1}, \hat{x}_{i,k-1}, \hat{x}_{j,k-1}, \bar{x}_{i,k-1|k-1}, m_{i,k-1}) \quad (6.27)$$

wobei:

$$h_{ji} = P\{m_k = m_j \mid m_{k-1} = m_i\}$$

Die Einträge der Transitionsmatrix aus (6.24) beschreiben die Wahrscheinlichkeiten zum Modellübergang und werden üblicherweise während der Schätz Aufgabe als zeitinvariant angenommen.

Der Unterschied zwischen der Implementierung als GPB1 und IMM besteht in der Reinitialisierungsstrategie zur Hypothesenreduktion:

Beide CMM-Formen verwenden alle Informationen aus dem vorherigen Filterschritt um die Schätzwerte x_i und P_{xi} neu zu initialisieren, während der GPB1 jedoch jedem Filter denselben Initialwert zur Verfügung stellt, erhält bei dem IMM jedes Filter einen individuellen Startwert. Hiermit lassen sich die Modellübergänge während der Reinitialisierung berücksichtigen und die Qualität der Schätzung gegenüber dem GPB1 steigern [92]. Die VSMM verfolgen neben einer Kooperationsstrategie zur optimierten Schätzung auch eine ständige Aktualisierung der genutzten Referenzmodelle, seien hier jedoch nur der Vollständigkeit halber erwähnt, da für die Implementierung des Prognosekonzeptes nur SM und CMM Anteile verfolgt worden sind. Eine ausführliche Beschreibung der Grundlagen für die verschiedenen *Multiple Model*-Ansätze ist in [92] gegeben.

4.5.2. Hybride Systemidentifikation

Die hybride Systemidentifikation zielt darauf ab, für einen gegebenen Datensatz mehr als ein Modell herzuleiten, falls der gesamte Wertebereich durch ein einzelnes Modell nicht hinreichend genau abgebildet werden kann. Hierfür ist analog zur hybriden Filterung die Identifikationsaufgabe um die Bestimmung einer diskreten Kennzahl zur Klassifikation der Trainingsdaten erweitert worden. Durch diese Klassifikation ist gewährleistet, dass für jeden Datenbereich ein individuelles und auf diesen Wertebereich optimal angepasstes Modell identifiziert werden kann. Die einzelnen Modelle können in der Anwendungsphase durch eine beliebige Kooperationsstrategie als *Multiple Model*-Ansatz genutzt werden. Aus dieser Herangehensweise ergibt sich die Notwendigkeit während der Trainingsphase eine SM-Strategie zu nutzen, für die ein ausgewählter Indikator als Unterscheidungskriterium zur Datenklassifikation und damit auch zur Modellklassifikation dient. Um eindeutige Modelle zu erhalten und für ein *Multiple Model*-Konzept das Kriterium A2 (s. § 4.5.1.1) zu erfüllen, muss der gewählte Indikator den gesamten Wertebereich der Trainingsdaten abdecken und eine eindeutige Zuordnung der Modelle zu den unterschiedlichen Datenbereichen ermöglichen. Die Vorauswahl zur Identifikation der einzelnen Modelle erfolgt für jeden Zeitschritt anhand des gewählten Indikators:

$$m_k = z_i \mid f(u_k, y_k) \in c_i \quad (6.28)$$

wobei:

$$c_i \in C \mid c_i \notin c_j, \forall i, \forall j, i \neq j$$

$$u_k \in U, y_k \in Y, f(U, Y) = C$$

Hierbei kann $f(u, y)$ eine beliebige Funktion zur Datenklassifikation sein, die lediglich eine eindeutige Zuordnung der identifizierten Modelle zu den unterschiedlichen Wertebereichen c_i aus dem Lösungsraum C ermöglichen muss. Die Systemidentifikation verläuft ähnlich wie die Generierung eines fusionierten Schätzwertes bei *Multiple Model*-Ansätzen, indem für jeden Iterationsschritt j der gewichtete Ausgabewert aller Modellstrukturen $g_i(u, y)$ genutzt wird, um das Ergebnis zu bilden und damit die Modelle zu bewerten:

$$\hat{y}_{j,k} = \frac{\sum_{i=1}^M \mu_{i,k} \cdot \hat{g}_i(u_k, y_k)}{\sum_{i=1}^M \mu_{i,k}} \quad (6.29)$$

$$\varepsilon_j = \sqrt{\frac{\sum_{k=1}^N (\hat{y}_{j,k} - y_k)^2}{N}} \quad (6.30)$$

wobei:

$$\mu_{i,k} \begin{cases} 1 & f(u_k, y_k) \in c_i \\ 0 & f(u_k, y_k) \notin c_i \end{cases}$$

Die Lösungsfindung zielt darauf ab, alle Modellstrukturen simultan zu optimieren, da ein gutes Ergebnis nur dann erzielt werden kann, wenn alle Modelle ihren Bereich hinreichend genau abbilden können. Für die *Genetische Programmierung* wird hierzu die in § 4.2 beschriebene *Multi-Gene Regression* verwendet, bei der jedes Gen ein Teilmodell darstellt und die Modellgewichtung aus dem Wert des Indikators zur Datenklassifikation abgeleitet wird.

Zur Veranschaulichung sind in Abbildung 40 und Abbildung 41 jeweils die Ergebnisse einer Systemidentifikation ohne und mit hybridem Ansatz dargestellt. Das gewählte Beispielsystem wird durch folgende Gleichungen gebildet:

$$\begin{aligned}
 g_k &= u_{1T,V,k} + u_{2,k} \\
 h_k &= 7,5 \cdot \sqrt{u_{1T,V,k}} + u_{2,k} \\
 y_k &= g_k \cdot \delta + h_k \cdot (1 - \delta) + w_k \\
 \text{wobei: } \delta &\begin{cases} 1 & 500 \leq n \leq 1000 \\ 0 & n < 500, \dots, 1000 < n \end{cases} \\
 f(u_k, y_k) &= y_k \\
 C &= Y \\
 -\infty &\leq c_1 \leq 11 < c_2 \leq +\infty
 \end{aligned}$$

mit:

- $u_{1T,k}$ = Zufallsvariable mit Poissonverteilung ($\lambda_{u1T} = 0,1$)
- $u_{1V,k}$ = Zufallsvariable mit Normalverteilung ($\mu_{u1V} = 0,1$; $\sigma_{u1V}^2 = 0,25$)
- $u_{2,k}$ = Zufallsvariable mit logarithmischer Normalverteilung ($\mu_{u2} = 0,5$; $\sigma_{u2}^2 = 0,0625$)
- w_k = Normalverteilte Zufallsvariable ($\mu_w = 0$; $\sigma_w^2 = 10^{-3}$)
- N = Anzahl der Messpunkte ($n = 1:1500$)

Ohne hybriden Ansatz (s. Abbildung 40) kann die Systemidentifikation kein Modell zur ganzheitlichen Abdeckung des vorgegebenen Messbereiches identifizieren und minimiert den mittleren Fehler, indem das hergeleitete Modell einen gewichteten Mittelwert zwischen g_k und h_k liefert. Die Änderung in der durchschnittlichen Fitness während der Modellidentifikation ist über die betrachteten 50 Generationen vernachlässigbar, weswegen auch für spätere Generationen keine Verbesserung mehr zu erwarten ist.

Für die Nutzung des hybriden Ansatzes mit Datenklassifikation lassen sich zwei unabhängige Modelle identifizieren, die auch für die Validierungsphase gute Ergebnisse liefern (s. Abbildung 41). Die gefundene Lösung konvergiert bereits nach 10 Generationen gegen den erreichten Zielwert und nach 32 Generationen ist bis zum Abschluss der Systemidentifikation keine Verbesserung mehr erzielt worden, weswegen davon ausgegangen werden kann, dass ein lokales oder globales Optimum erreicht wurde.

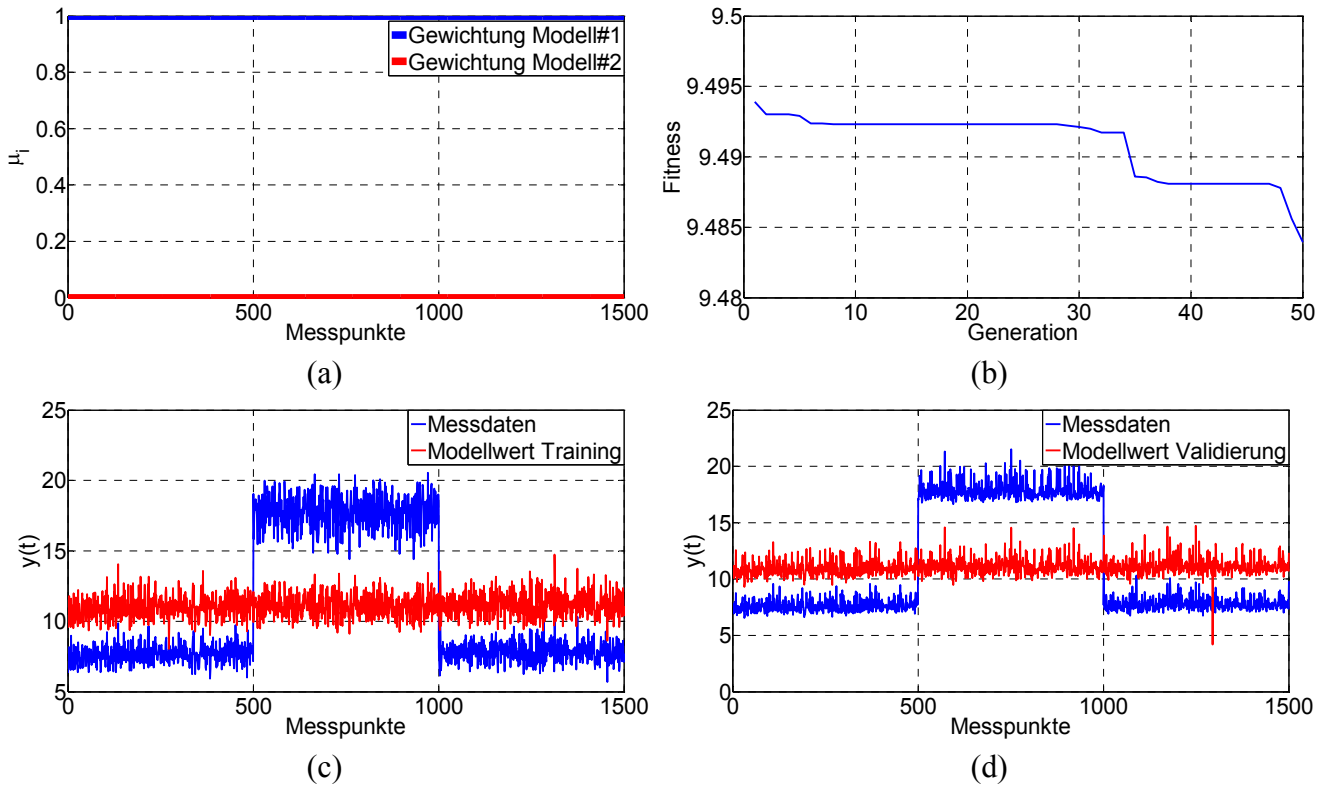


Abbildung 40: Single Model Systemidentifikation für hybrides System: (a) Modellgewichtung, (b) Fitnessrend, (c) Modelltraining, (d) Modellvalidierung

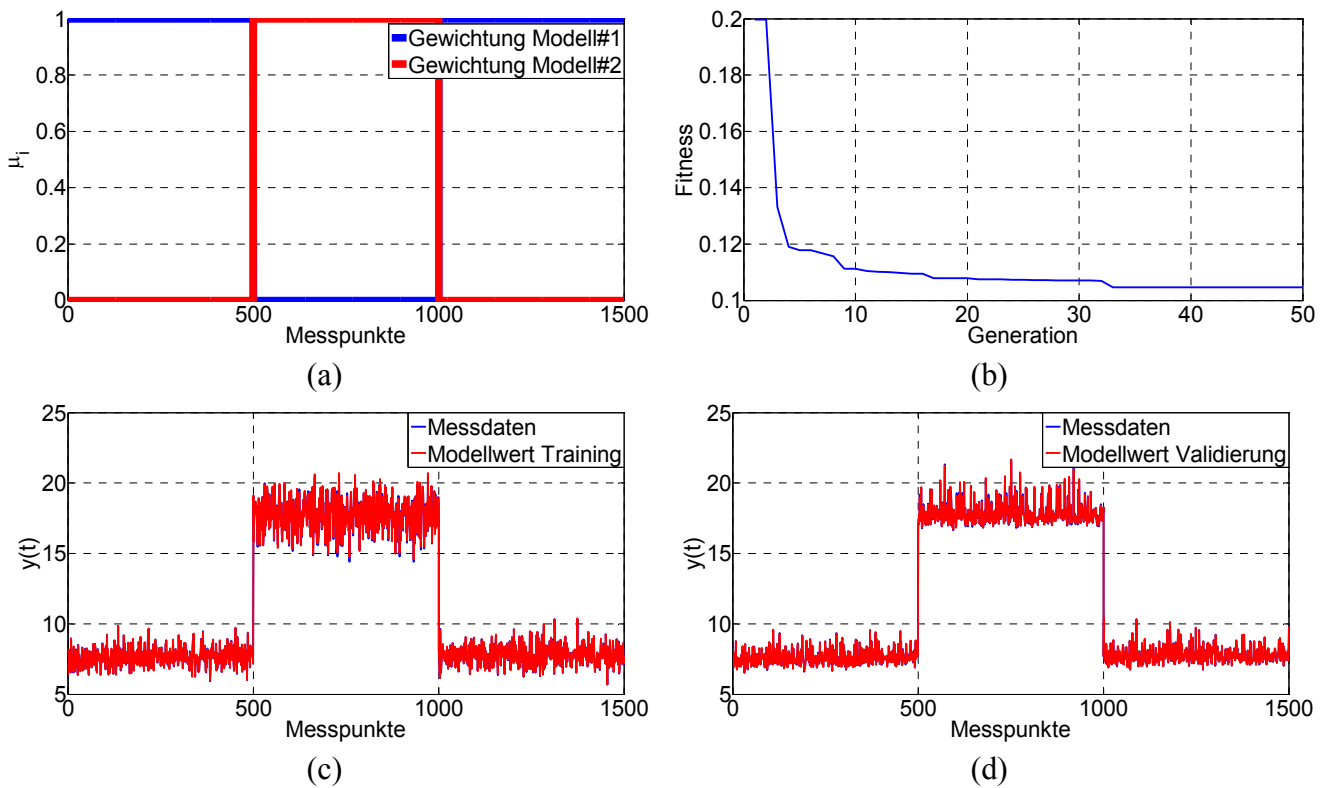


Abbildung 41: Multiple Model Systemidentifikation für hybrides System: (a) Modellgewichtung, (b) Fitnessrend, (c) Modelltraining, (d) Modellvalidierung

Die Ergebnisse zeigen anhand des gewählten Beispielsystems, dass die Strategie geeignet ist, um eine hybride Implementierung der Systemidentifikation zu ermöglichen. Durch die Wahl eines ge-

eigneten Indikators kann durch die Klassifikation der Trainingsdaten die Herleitung von lokal optimierten Modellen unterstützt werden. Diese auf den jeweiligen Wertebereich c_i optimierten Modelle können dann in der Anwendungsphase bei entsprechender Verfügbarkeit des während des Trainings genutzten Auswahlkriteriums für eine beliebige *Multiple Model*-Strategie genutzt werden.

Die Auflösung der Datenklassifikation C und damit auch die Anzahl der zu identifizierenden Modelle, kann beliebig hoch gewählt werden.

Einzige Voraussetzung ist, dass jedes Modell einen geeigneten Datensatz zum Training erhält und die Zuordnung der Trainingsdaten zu den einzelnen Modellen eindeutig ist, da sonst keine *Single Model*-Strategie umgesetzt werden kann.

4.5.3. Modellbasierte Systemidentifikation mit hybridem Filteransatz

Für die Anwendung mit integriertem UKF wird die in § 4.4 beschriebene Implementierung an die Form der hybriden Systemidentifikation angepasst. Hierzu muss (6.29) um die Filtergleichungen erweitert werden:

$$\hat{y}_{j,k} = \frac{\sum_{i=1}^M \mu_{i,k} \cdot \hat{h}_i(u_k, \hat{f}_i(u_{k-1}, \hat{x}_{i,k-1}, \hat{\xi}_{i,k-1}))}{\sum_{i=1}^M \mu_{i,k}} \quad (6.31)$$

Die in § 4.4 hergeleiteten Bewertungskriterien $Y = \{\nu_I, \dots, \nu_S\}$ müssen zusätzlich angepasst werden, um den hybriden Ansatz der Systemidentifikation mit mehreren Modellen zu berücksichtigen:

$$\nu_{j,s} = \frac{\sum_{i=1}^M \sum_{k=1}^N \mu_{i,k} \cdot \nu_{i,s}}{\sum_{i=1}^M \sum_{k=1}^N \mu_{i,k}} \quad (6.32)$$

Somit wird die Verteilung der Indikatoren zur Datenklassifikation für die hybride Systemidentifikation bei der Bewertung der einzelnen Modellstrukturen berücksichtigt. Die weitergehende Auswertung der Fitness für die einzelnen Modellkandidaten verläuft analog zu der beschriebenen Vorgehensweise für die modellbasierte Systemidentifikation mit einem einzelnen Modell. Hierfür wird jedes Bewertungskriterium ν_i auf der Modellebene m_i für den jeweiligen Datenbereich c_i ausgewertet und dann mittels (6.32) eine gesamtheitliche Aussage für das jeweilige Individuum bestimmt. Somit wird nur dann ein gutes Gesamtergebnis erzielt, wenn alle Teilmodelle ihren Datenbereich hinreichend gut abdecken können.

Der funktionale Ablauf der hybriden modellbasierten Systemidentifikation ist zusammenfassend in Abbildung 42 dargestellt:

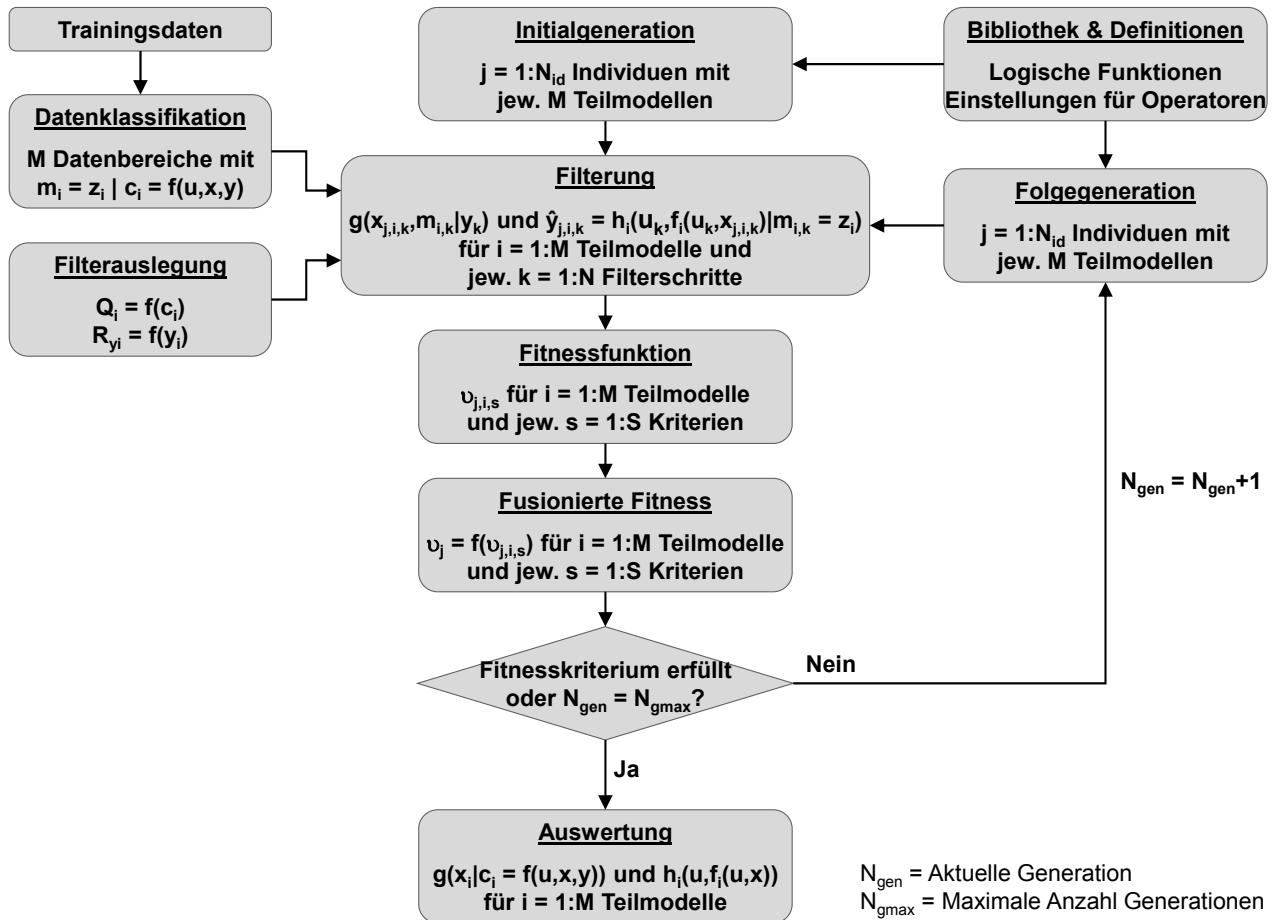


Abbildung 42: Implementierung der hybriden modellbasierten Systemidentifikation

5. Hybride Fehlerprognose

In diesem Abschnitt werden zunächst die wesentlichen Grundlagen zur Implementierung von Prognosefunktionen beschrieben. Aufgrund des gewählten Ansatzes, die Prognose mit einem hybriden UKF durchzuführen, liegt der Fokus der Studien hierbei auf der Implementierung von rekursiven bayesschen Schätzern als Prognosemodul. Neben den Erweiterungen des UKFs für Prognose, wird ein neuer hybrider Ansatz für Prognose mit einer integrierten Form von daten- und modellbasierten Anteilen beschrieben. Ausgehend von den Erfahrungen der experimentellen Versuche ist ein Verfahren zur Handhabung von empirisch verteilten Grenzwerten für die maximal zulässige Schadensgröße hergeleitet worden. Die Motivation und Vorgehensweise zur Implementierung des GP-UKF-Ansatzes werden allgemeingültig und anhand eines Beispiels diskutiert. Des Weiteren wird ein in [97] beschriebenes Verfahren zur datenbasierten Optimierung der Prognoseergebnisse erweitert und abschließend die ganzheitliche Implementierung als hybrides Prognosekonzept dargestellt.

5.1. Aufgaben der Fehlerprognose

Die Aufgabe der Fehlerprognose besteht in der frühzeitigen Bewertung von Anzeichen für zukünftige oder bereits beginnende Fehlerausprägungen, um für diese dann mit geeigneten Methoden den weiteren Verlauf bis zum Fehlerfall zu prognostizieren [98]. Dafür gelten folgende Annahmen, die erfüllt sein müssen [33]:

1. Alle elektromechanischen Komponenten degradieren als Funktion der Nutzung, Betriebszeit und Umgebungsbedingungen.
2. Die Degradierung ist ein monotoner Prozess, der sich durch eine Änderung der chemischen und physikalischen Eigenschaften der Komponente ausdrückt.
3. Direkte oder indirekte Anzeichen der Degradierung sind bereits vor dem Komponentenausfall erkennbar.
4. Eine Korrelation dieser Anzeichen mit der verbleibenden Nutzungsdauer ist möglich.

Zur Gewährleistung der letzten Annahme muss eine maximal zulässige Schadensgröße CI_{max} definiert werden, deren Überschreitung als Kriterium zur Vorhersage des Ausfallzeitpunktes verwendet werden kann. Nach [99] besteht die Herausforderung für die Prognose zunächst in der Entwicklung eines geeigneten Modells zur Prädiktion von Schadensmerkmalen sowie diesem Modell dann geeignete CIs bereit zu stellen. Die Zuordnung von Diagnose und Prognose ist hierbei in der Literatur nicht immer einheitlich gehalten, so werden Prognosekonzepte häufig auch mit integriertem Diagnosemodul dargestellt [100]. Im Folgenden wird die funktionale Unterscheidung zwischen Diagnose und Prognose getroffen, die auch in [99] gegeben ist: Diagnose und Prognose werden als unabhängige Funktionen definiert, wobei die Diagnose einen geeigneten CI bereit stellt und die Prognose den Verlauf des CIs für zukünftige Nutzungsprofile bestimmt. Die funktionale Anbindung der

beiden Elemente erfolgt durch die Übergabe der Historie des CIs, der zugehörigen Betriebsbedingungen und aller mit der Diagnose in Verbindung stehenden Unsicherheiten, die bei der Prognose berücksichtigt werden müssen. Bis zum Startpunkt der Prognose sind hierfür durch geeignete Diagnosefunktionen der CI und zugehörige Unsicherheiten zur Quantifizierung der Schadensgröße möglichst exakt zu bestimmen.

In der Prädiktionsphase akkumulieren sich die Unsicherheiten in der Bestimmung der Schadensgröße, der Vorhersage des Schadensverlaufes und dem Einfluss der zukünftigen Nutzungsprofile [98]. Des Weiteren verläuft die Degradierung von zwei Komponenten auch bei gleicher Bau- und Nutzungsweise nicht zwangsläufig identisch [101]. Die Aussage der Prognose muss diese Unsicherheiten berücksichtigen und somit definiert sich die Berechnung des geschätzten Ausfallzeitpunktes („*End of Prediction*“ - EoP) und der daraus abgeleiteten geschätzten verbleibenden Nutzungsdauer RUL* als eine Bestimmung der statistischen Eigenschaften von Zufallszahlen [102]. Um hierbei eine Risikoabschätzung für prädiktive Wartungs- und Missionsplanungen zu ermöglichen, sind neben dem Erwartungswert auch ausgewählte Perzentilen der Wahrscheinlichkeitsverteilungen für EoP und RUL* von Interesse. Das Minimalziel der Fehlerprognose ist es für EoP und RUL* die ersten beiden statistischen Momente zu bestimmen. Falls möglich können über den Verlauf der Dichteverteilung der prognostizierten Größe, deren Varianz mit dem Vorhersagenszeitraum stetig zunimmt [69], zusätzliche Informationen zur Bestimmung des Ausfallzeitpunktes als nicht deterministisch definierbare Größe gewonnen werden. Der vollständige funktionale Ablauf von der Datenerfassung über die Diagnose bis zur Prognose stellt sich damit wie folgt dar:

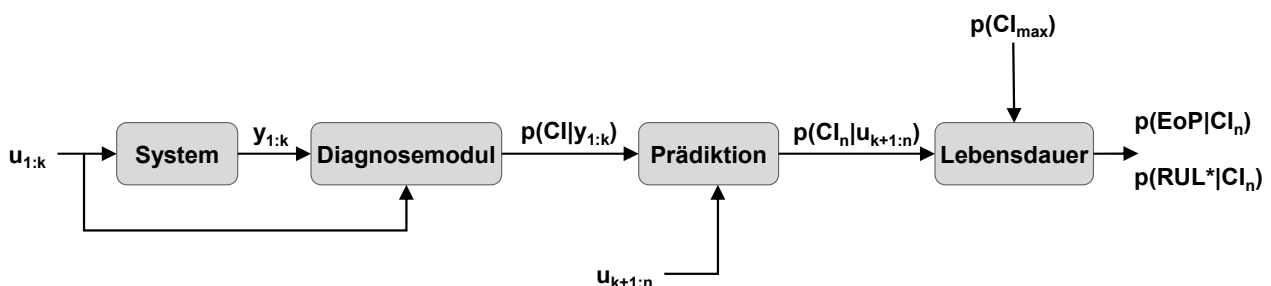


Abbildung 43: Funktionaler Ablauf ausgehend von der Datenerfassung über die Diagnose zur Prognose und der Bestimmung von EoP und RUL*

Die Prädiktion und Lebensdauerbestimmung kann sich hierbei je nach Prognoseansatz auch einer Datenbasis bedienen, um über die Korrelation mit vorhandenen Datensätzen die Prognose zu optimieren, bzw. überhaupt erst zu ermöglichen.

5.1.1. Unterstützung von prädiktiven Maßnahmen

Eine wesentliche Zielsetzung der Fehlerprognose für luftfahrttechnische Systeme ist die Unterstützung von prädiktiven Maßnahmen zur Steigerung der operationellen Leistungsfähigkeit [103]. Hierfür ist die Bestimmung des Verlaufs der statistischen Eigenschaften des gewählten CI unter Berücksichtigung der Unsicherheiten in der Bestimmung der Schadensgröße, der Vorhersage des Schadensverlaufes und dem Einfluss der zukünftigen Nutzungsprofile [98].

sichtigung der zukünftigen Nutzungsprofile $p(CI_n|u_{k+1:n})$ oder auch als rekursive Funktion des aktuellen Zustandes²¹ $p(CI_n|u_{k+1:n}, CI_{k:n-1})$ erforderlich. Anhand eines vordefinierten Grenzwertes für die Schadensgröße CI_{max} lassen sich daraus die Verteilung für den prognostizierten Ausfallzeitpunkt $p(EoP|CI)$ und der Erwartungswert der verbleibenden Nutzungsdauer $E[p(RUL^*|CI)]$ bestimmen:




Abbildung 44: Ausfallzeitpunkt EoP mit Dichteverteilung $p(EoP|CI)$ und RUL* mit Erwartungswert $E[p(RUL^*|CI)]$ aus prognostizierter Verteilung des CI mit Dichteverteilung $p(CI|u)$

Hierzu wird mittels (7.1) zunächst die prognostizierte Ausfallwahrscheinlichkeit („Probability of Failure“ - PoF) zum Zeitpunkt k durch den Verlauf der Verteilung des CI berechnet:

$$PoF_k = \int_{CI_{max}}^{\infty} p(CI_k | u_{1:k}, CI_{1:k-1}) dCI \quad (7.1)$$

Diese Aussage kann genutzt werden um die Risikoanalyse für prädiaktive Maßnahmen zu unterstützen. Je nach ökonomischen oder sicherheitsrelevanten Aspekten kann der Zeitpunkt zur prädiaktiven Wartungsmaßnahme mit einem entsprechenden Fehlerrisiko gewählt werden. Durch PoF_k ist das Integral der möglichen Ausfallzeitpunkte des prognostizierten Verlaufes $p(CI_k|u_{1:k}, CI_{1:k-1})$ bis zum Zeitpunkt k gegeben. Die Verteilung der Ausfallzeitpunkte $p(EoP|CI_k)$ entspricht dann einer Differenzierung von (7.1) nach der Nutzungsdauer t :

$$p(EoP|CI_k) = \frac{\partial PoF_{1:k}}{\partial t} \quad (7.2)$$

Die Verteilung für die geschätzte verbleibende Nutzungsdauer $p(RUL^*|CI_k)$ ergibt sich aus (7.2) mit dem Startpunkt der Prognose t_0 durch $p(EoP-t_0|CI_k)$, wodurch die Streuung um den Erwartungswert unverändert bleibt.

²¹ Für die meisten Degradierungsprozesse besteht ein Zusammenhang zwischen dem Einfluss von Betriebsbedingungen und dem aktuellen Zustand, wodurch in Abhängigkeit von der Art der Degradierung (chemisch, Verschleiß oder Ermüdung etc.) eine mit der Schadensgröße variierende Degradierungsrate beobachtet werden kann [68].

Der Prognosefehler ε_p und die gesuchten statistischen Momente $E[RUL^*]$ und $\sigma^2_{RUL^*}$ sind durch (7.3)-(7.5) mit EoL („*End of Life*“) als dem wahren Zeitpunkt für den prognostizierten Fehlerfall gegeben:

$$\varepsilon_p = EoL - E[p(EoP | CI)] \quad (7.3)$$

$$E[RUL^*] = \int_0^{\infty} ((t - t_0) \cdot p(EoP - t_0 | CI)) dt \quad (7.4)$$

$$\sigma^2_{RUL^*} = \int_0^{\infty} (((t - t_0) - E[RUL^*])^2 \cdot p(EoP - t_0 | CI)) dt \quad (7.5)$$

Der Verlust an operationeller Zeit E leitet sich aus der Differenz des Zeitpunktes zum Austausch t_k und EoL ab (Vorgehensweisen zur Auswahl eines geeigneten Zeitpunktes t_k werden in § 5.1.2 diskutiert):

$$E_k = EoL - t_k \quad (7.6)$$

Hierbei sind in Abhängigkeit des Wertes von E für den operationellen Betrieb folgende Bedingungen erfüllt:

$E \rightarrow 0$: Vermeidung von Fehler im Betrieb und minimierter Verlust an operationeller Zeit.

$E > 0$: Vermeidung von Fehler im Betrieb, jedoch Verlust an operationeller Zeit.

$E < 0$: Maximale Ausnutzung der operationellen Zeit, jedoch Fehler im Betrieb.

Für reale Anwendungen ist häufig ein nicht deterministisches Ausfallverhalten, bzw. eine Unkenntnis über den exakten Wert der maximal zulässigen Schadensgröße zu berücksichtigen [101]. Dadurch erhöht sich die Unsicherheit in der Bestimmung der PoF zusätzlich. Zur Berücksichtigung für die Fehlerprognose lässt sich mittels der Dichteverteilung $p(CI_k | u_{1:k}, CI_{1:k-1})$ zu einem beliebigen Zeitpunkt k , der Verteilungsfunktion für die maximal zulässige Schadensgröße $p(CI_{max})$ und unter Verwendung von (7.7) die erweiterte Ausfallwahrscheinlichkeit PoF_{CI} für eine Fehlerprognose mit verteilter Schadensgrenze bestimmen:

$$PoF_{CI,k} = \int_{CI=-\infty}^{CI=\infty} p(CI_k | u_{1:k}, CI_{1:k-1}) \cdot p(CI_{max}) \cdot dCI \quad (7.7)$$

Die Funktion $PoF_{CI,k}$ beschreibt hierbei analog zu (7.1) die Wahrscheinlichkeit des Fehlerfalls zum Zeitpunkt k und ermöglicht so auch für nicht deterministische Grenzwerte eine Risikobetrachtung (s. Abbildung 45). Die Bestimmung der Verteilung $p(EoP | CI)$ und den daraus abgeleiteten Momenten $E[RUL^*]$ und $\sigma^2_{RUL^*}$ erfolgt auch für nicht deterministische Grenzwerte ausgehend von (7.7) analog zu (7.2)-(7.5).




Abbildung 45: Ausfallwahrscheinlichkeit PoF_{CI} für prognostizierte Verteilung des CI mit Dichteverteilung $p(CI|u)$ und verteilter Schadensgrenze mit Dichteverteilung $p(CI_{max})$

Für eine Anwendung zur prädiktiven Wartungsplanung ist neben der Vermeidung von Fehlern auch das Verhältnis zwischen dem Prognosehorizont und der logistischen Vorlaufzeit von Interesse. Der Prognosehorizont muss gewährleisten, dass die Bereitstellung der Ressourcen für eine prädiktive Maßnahme auch möglich ist, bevor der Fehlerfall zu einer Unterbrechung des Betriebes führt [98]. Ansonsten würde der Austausch den Fehlerfall zwar vermeiden aber das System aufgrund der fehlenden Ressource nicht einsatzfähig sein.

Durch eine Verschiebung des Startpunktes der Prognose t_0 gegen EoL, bzw. bei Verfügbarkeit von neuen Daten aus dem Diagnosesystem, liegen jeweils aktuellere Informationen über den momentanen Zustand und bisherigen Schadensverlauf vor. Dadurch reduziert sich der Anteil der Unsicherheiten während der Prognosephase, womit die Bestimmung eines geeigneten Zeitpunktes zur prädiktiven Instandsetzung zuverlässiger wird. Diese mit steigendem Verhältnis zwischen t_0 und EoL verbesserte Prognosequalität drückt sich üblicherweise durch eine Reduzierung des Betrags des Prognosefehlers ε_p und der Varianz σ_{RUL}^2 aus [103], [98]:




Abbildung 46: Einfluss des Startpunktes t_0 auf die Qualität der Prognose

Dieses Konvergenzverhalten kann genutzt werden, um zu beurteilen ob ein Prognosekonzept ab einem bestimmten Startpunkt $t_{0,k}$ vorgegebene Kriterien für einen maximalen Prognosefehler ε_{Pmax} oder eine maximale Unsicherheit $\sigma^2_{RUL,max}$ erfüllt:

$$|\varepsilon_{P,k:N}| \leq |\varepsilon_{Pmax}| \quad \forall t_{0,k:N} \quad (7.8)$$

$$\sigma^2_{RUL*,k:N} \leq \sigma^2_{RUL*max} \quad \forall t_{0,k:N} \quad (7.9)$$

5.1.2. Auswahl eines geeigneten Kriteriums zur prädiktiven Planung

Die Auswahl eines geeigneten Zeitpunktes zur Umsetzung der prädiktiven Maßnahme lässt sich nicht allgemeingültig durchführen. Je nach Anwendungsfall ist entweder das Risiko für einen Fehlerfall zu minimieren, die Laufzeit zu maximieren, oder die logistische Vorlaufzeit zur Ressourcenerbereitstellung ein limitierender Faktor:




Abbildung 47: Kriterium für prädiktive Planung der Instandsetzung: (a) Reduziertes Fehlerrisiko, (b) Erhöhte Laufzeit, (c) Logistische Vorlaufzeit

Wenn kein vorgegebenes Kriterium für die zulässige PoF besteht und der Prognosehorizont größer oder gleich der logistischen Vorlaufzeit ist, können wie bei der hybriden Filterung (s. § 4.5.1) die MMSE- oder MAP-Kriterien zur Auswahl eines geeigneten Zeitpunktes zur Umsetzung der prädiktiven Maßnahme verwendet werden. Je nach EoP-Verteilungstyp und Zielsetzung der Prognose (Erhöhung der Verfügbarkeit oder Gewährleistung der Sicherheit im Betrieb) kann eines der Kriterien bevorzugt werden (s. [Abbildung 48](#)) [98]. Eine zwischen Sicherheit und Verfügbarkeit ausgeglichene Strategie bietet sich unabhängig von der Verteilungsform durch den Zentralwert der EoP-Verteilung mit PoF = 50% an. Durch die Wahl des Zentralwertes der EoP-Verteilung als Zeitpunkt zur prädiktiven Instandsetzung erhält der Anteil der reduzierten Verfügbarkeit die gleiche Gewichtung wie das prognostizierte Fehlerrisiko. Voraussetzung für die durchgeführten Betrachtungen ist, dass der wahre Wert EoL innerhalb des Wertebereiches der EoP-Verteilung liegt:

$$0 < \int_{-\infty}^{EoL} p(EoP|CI) dt < 1 \quad (7.10)$$

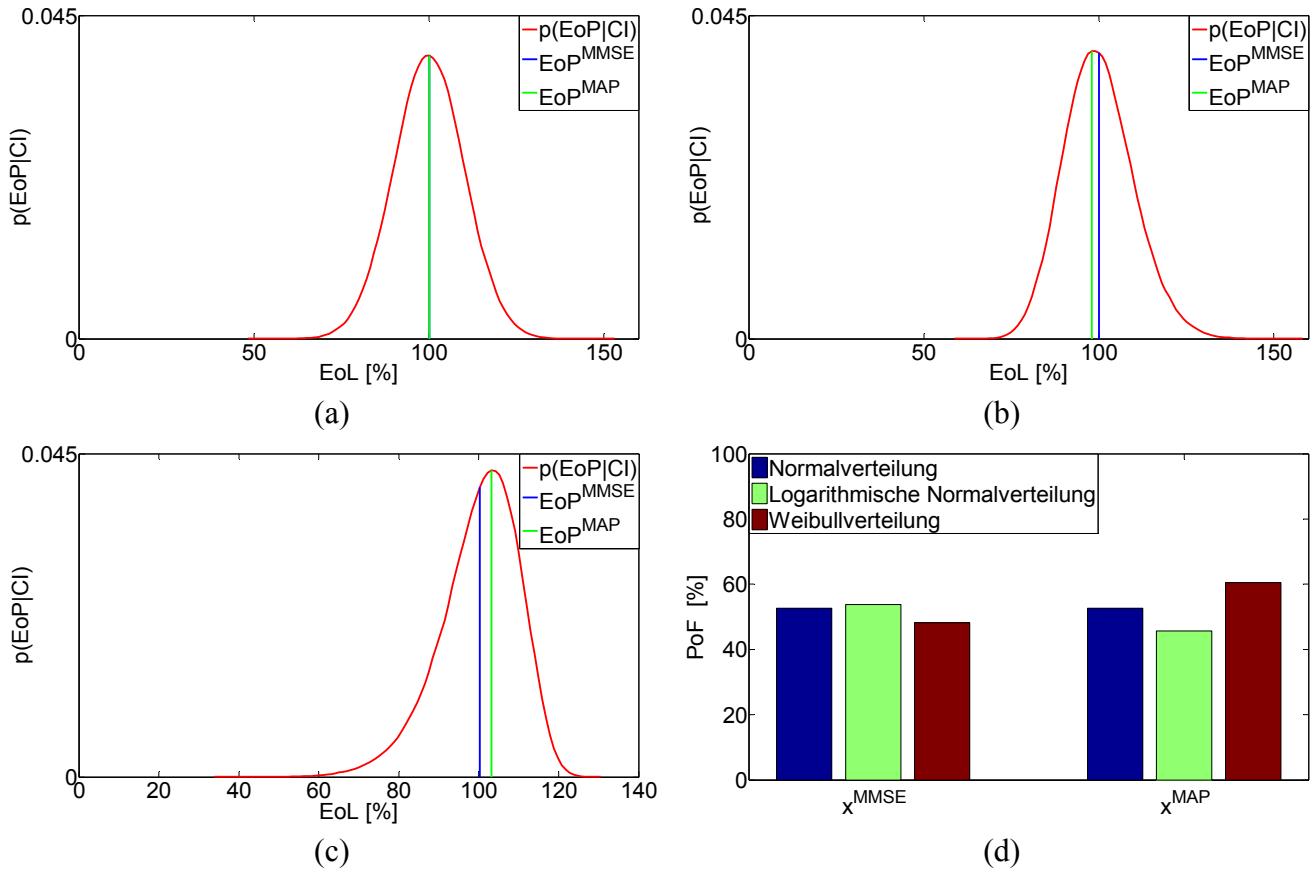


Abbildung 48: Einfluss EoP-Verteilungstyp auf prädiktive Planung für MMSE und MAP: (a) Normalverteilung, (b) Logarithmische Normalverteilung, (c) Weibullverteilung, (d) PoF für MMSE und MAP

5.2. Propagierung von statistischen Eigenschaften

Da alle für die Prognose relevanten Informationen in den Verteilungen $p(\text{CI}_k|u_{1:k}, \text{CI}_{1:k-1})$ und $p(\text{EoP}|\text{CI}_k)$ enthalten sind, stellt die Vorgehensweise zur Bestimmung des Verlaufes ihrer statistischen Eigenschaften eine der zentralen Aufgaben der Prognose dar [103]. Hierfür müssen geeignete Verfahren zur Propagierung der statistischen Eigenschaften des CIs zur Anwendung kommen. Für lineare Systeme wird die exakte Lösung durch lokale Expansionen wie die Taylorreihenentwicklung [104] oder Neumannsche Reihe [105] angenähert. Unter der Annahme, dass ein geeignetes Modell zur Propagierung der Schadensgröße $f(\text{CI})$ vorhanden ist und die Modelleingänge u_i nicht korreliert sind, kann der allgemeingültige Ansatz aus [106] verwendet werden:

$$\sigma_{\text{CI},k} = \sqrt{\sum_{i=1}^M \left[\frac{\partial f(\text{CI})}{\partial u_i} \cdot \sigma_{u_i}^2 \right] + \frac{\partial f(\text{CI})}{\partial \text{CI}_{k-1}} \cdot \sigma_{\text{CI},k-1}^2} \quad (7.11)$$

Für kontinuierliche, nichtlineare Systeme liefert die Fokker-Planck-Kolmogorov Gleichung eine exakte Lösung, während für diskrete Systeme die Chapman-Kolmogorov Gleichung Gültigkeit besitzt [107], [108]. Bisher ist für diese Ansätze jedoch keine allgemeingültige, analytisch geschlossene Lösung bekannt, weswegen die Implementierung für nichtlineare, stochastische Prozesse üblicherweise durch variationelle Ansätze vorgenommen wird [107].

Wenn der zu prognostizierende Prozess ein stochastisches Verhalten der Eingangsgrößen oder des Prozessmodells aufweist, sind Monte-Carlo Simulationen mit multiplen Trajektorien eine zwar rechenintensive aber unkomplizierte und robuste Methode um den Verlauf der Dichteverteilung $p(CI_k|u_{1:k}, CI_{1:k-1})$ anzunähern [109]. Die wohl prominentesten Vertreter für dieses Verfahren aus dem Bereich der sequenziellen Monte-Carlo Simulationen sind Partikelfilter [110]. Voraussetzung hierfür ist, dass der zu erwartende Ergebnisraum durch die Menge der Trajektorien hinreichend genau abgedeckt wird, um die statistischen Eigenschaften der wahren Verteilung abzubilden.

Aufgrund ihrer Eignung unter Kenntnis der verfügbaren Messwerte $y_{1:k}$ eine Prädiktion der Dichteverteilung von Modellgrößen $p(x_k|y_{1:k})$ zu ermöglichen, finden auch bayessche Verfahren aus dem Bereich der Regression [111] sowie der rekursiven Filterung [112], [113] ein breites Anwendungsspektrum in der Propagierung von statistischen Eigenschaften. Die „*Unscented Transformation*“ [81] bietet eine besonders effiziente Methode eine Dichteverteilung durch Annäherung des Erwartungswertes und der Varianz mit einer minimalen Anzahl an Trajektorien auch für nichtlineare Systeme zu propagieren [114]. Eine weitere Form der Implementierung aus dem Bereich der rekursiven bayesschen Filterung wird in [87] genutzt, bei der während der Prognosephase der Korrekturschritt des Kalman-Algorithmus vernachlässigt wird und die Prognose somit aus einer reinen Prädiktion des Zustandes und der Kovarianzen unter Verwendung der Prozess- und Beobachtergleichungen besteht.

Die Auswahl der Methode zur Annäherung der Dichteverteilung $p(CI_k|u_{1:k}, CI_{1:k-1})$ wird ähnlich wie für das gesamte Prognosekonzept durch die Verfügbarkeit der Daten zur Erzeugung von Einzeltrajektorien, der Kenntnis über die Modellstrukturen und Modelleigenschaften sowie des genutzten Prognoseansatzes und der verfügbaren Rechenleistung bestimmt.

5.3. Anpassungen des GP-UKF für Prognose

Für die Implementierung der Prognosefähigkeiten des untersuchten GP-UKF-Ansatzes ist neben der Erweiterung der Bewertungskriterien zur Modellauswahl auch der verwendete UKF-Algorithmus anzupassen, um eine Propagierung der statistischen Eigenschaften des CI zu ermöglichen.

Die hierfür gewählten Methoden sowie die Erweiterung der Prognose durch den in § 4.5.3 hergeleiteten *Multiple Model*-Ansatz werden im Folgenden näher beschrieben.

5.3.1. Erweiterung der Bewertungskriterien zur Modellauswahl

Zur Unterstützung der Modellauswahl für das Prognosekonzept sind die in § 4 beschriebenen Kriterien F1-F4 durch die nachfolgend definierten Kriterien F5-F7 erweitert worden. Hiermit wird die Eignung zur Prognose anhand bekannter Degradierungsverläufe bewertet. Für N_T verschiedene Testläufe mit jeweils N_S Prognosestartwerten $t_{0,1:N_S}$ werden der mittlere quadratische Fehler des

prognostizierten CI-Verlaufes ($RMSE_P$) sowie der mittlere prozentuale Fehler (MAPE) und die Standardabweichung (SSD) des Prognosefehlers ε_P zur Bewertung verwendet:

$$\text{Kriterium F5:} \quad RMSE_P = \frac{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} \sqrt{\frac{\sum_{k=1}^{N_{i,j}} v_{i,j,k}^2}{N_{i,j}}} \cdot w(\lambda_{i,j})}{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} w(\lambda_{i,j})} \quad (7.12)$$

$$\text{Kriterium F6:} \quad MAPE = \sum_{i=1}^{N_T} \left(\frac{\sum_{j=1}^{N_S} \left(\frac{\varepsilon_{P,i,j}}{EoL_i} \cdot w(\lambda_{i,j}) \right)}{\sum_{j=1}^{N_S} w(\lambda_{i,j})} \right) \cdot \frac{1}{N_T} \cdot 100 \quad (7.13)$$

$$\text{Kriterium F7:} \quad SSD = \sqrt{\frac{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} ((\varepsilon_{P,i,j} - \bar{\varepsilon}_P)^2 \cdot w(\lambda_{i,j}))}{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} w(\lambda_{i,j}) - \bar{w}(\lambda)}} \quad (7.14)$$

wobei:

$$v_{i,j,k} = y_{i,j,k} - \hat{y}_{i,j,k} \quad (7.15)$$

$$\hat{y}_{i,j,k} = h(\hat{u}_{i,j,k}, f(\hat{u}_{i,j,k-1}, \hat{x}_{i,j,k-1}, \hat{\xi}_{i,j,k-1})) \quad (7.16)$$

$$\lambda_{i,j} = \frac{t_{0,i,j}}{EoL_i} \quad (7.17)$$

$$w(\lambda_{i,j}) = \exp\left(\lambda_{i,j} - \arg \max_{\lambda} \{\lambda_i\}\right) \cdot p_{\lambda} \quad (7.18)$$

$$\bar{w}(\lambda) = \frac{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} \lambda_{i,j}}{N_T \cdot N_S} \quad (7.19)$$

mit:

N = Anzahl der Prädiktionsschritte bis ein vordefiniertes Kriterium erfüllt ist

$\bar{\varepsilon}_P$ = Mittelwert Prognosefehler $\varepsilon_{P,i,j}$ über alle Testläufe $i = 1:N_T$ und $j = 1:N_S$

Der Abweichung $v_{i,j,k}$ des prognostizierten Wertes zum aktuellen Zeitschritt k für Testlauf i und Startpunkt der Prognose j wird anhand des Vergleiches mit dem wahren Verlauf $y_{i,j,k}$ bestimmt. Somit wird bewertet, wie gut die Prognose den Verlauf des verwendeten Trainingsdatensatzes abbilden kann.

Die Eingabewerte $u_{i,j,k}$ werden innerhalb des vorhandenen Datensatzes exakt wiedergegeben und außerhalb ($RUL^* > RUL$) aus dem arithmetischen Mittel der vorhandenen Daten gebildet.

Für eine rekursive Modellierung mit $CI_{i,j,k-1}$ als Modelleingabewert für den Zeitschritt k_{ij} ist der Trainingsdatensatz $u_{i,j}$ entsprechend bei jedem Prognoseschritt $k_{i,j}+1$ mit dem prognostizierten Wert $CI_{i,j,k}$ zu erweitern.

Die Normierung (7.17) wird verwendet, um die Bewertung der Konvergenz von Prognosefähigkeiten unabhängig von der Länge des verwendeten Testszenarios durchzuführen. Mittels der exponentiellen Gewichtung durch (7.18) kann über den Skalierungsfaktor p_λ die in § 5.1.1 beschriebene erhöhte Relevanz von späteren Startpunkten der Prognose berücksichtigt werden. Durch die Normierung mit EoL_i liegt $\lambda_{i,1:N_S}$ immer im Intervall $[0,1]$.

Mit diesen zusätzlichen Kriterien werden alle relevanten Eigenschaften der Prognosephase (Fähigkeit den Verlauf wiederzugeben, den Ausfallzeitpunkt zu bestimmen und die Stabilität der Prognose) unter Berücksichtigung des Startpunktes der Prognose in der Modellauswahl berücksichtigt. Eine detaillierte Betrachtung der Präzision zur Modellbewertung anhand der Vertrauensbereiche für jeden prognostizierten Verlauf ist ebenfalls möglich. Ein möglicher Ansatz hierfür wäre der Vergleich des wahren Ausfallzeitpunktes mit einer vorgegebenen PoF, bzw. die Differenz zwischen zwei Perzentilen der Verteilung $p(EoP|CI)$. Zur Reduzierung der Komplexität und weil wie in [98] beschrieben eine geringere Varianz der Prognose σ_{RUL}^2 nicht zwangsläufig auch eine Optimierung der Laufzeiten oder Sicherheit bedeutet²², wurde kein entsprechendes Kriterium aufgestellt.

Die Vorgehensweisen zur Bestimmung des gewichteten Mittelwertes gemäß (6.16) und für den *Multiple Model*-Ansatz nach (6.32) bleiben unverändert gültig.

5.3.2. Hybride Filterauslegung als Prognosefunktion

Für die durch den GP-UKF identifizierte Modellstruktur ist ein datenbasiertes Verfahren aufgestellt worden, um den Erwartungswert und die Varianz der geschätzten Störgröße ξ (s. § 4.4.1) für den Prädiktionsschritt des UKFs als Funktion der Eingabegrößen der Modellgleichungen zu bestimmen. Zusätzlich wurde der verwendete UKF-Algorithmus angepasst, um die Prädiktion von Modellgrößen ohne Verfügbarkeit von Messwerten auch über multiple Filterschritte zu ermöglichen.

Die Vorgehensweise zur Implementierung dieser Fähigkeiten wird im Folgenden dargestellt.

5.3.2.1. Datenbasiertes Prozessmodell

Die in § 4.4 beschriebene modellbasierte Systemidentifikation stellt als Lösung ein hybrides Systemmodell mit datenbasiertem Anteil für die zeitvariante Störgröße ξ zur Verfügung. Während das Beobachtermodell des integrierten UKFs nach (6.5) durch eine wahlweise nichtlineare Funktion

²² Nach [98] besteht das Paradoxon der Prognose darin, dass die Wahrscheinlichkeit die Verteilung $p(EoL)$ korrekt zu prognostizieren mit zunehmender Präzision der Prognose abnimmt.

$h(u_k, x_k)$ beschrieben wird, unterstützt die Störgröße ξ die prognostizierte Änderung des Modellzustandes x als Datenmodul $g(u_k, \xi_k)$:

$$\begin{aligned}\xi_{k|k-1} &= g(u_{k-1}, \xi_{k-1}) \\ x_k &= f(u_{k-1}, x_{k-1}, \xi_{k|k-1}) \\ y_k &= h(u_k, x_k)\end{aligned}\quad (7.20)$$

mit:

$g(u, \xi)$ = Datenmodul aus Systemidentifikation

$f(u, x, \xi)$ = Prozessmodell aus Systemidentifikation

$h(u, x)$ = Beobachtermodell aus Systemidentifikation (wird als bekannt vorausgesetzt)

Das Datenmodul $g(u, \xi)$ besteht hierbei aus den Verteilungsfunktionen $f(\xi_k|u_{1,k}), \dots, f(\xi_k|u_{n,k}), f(\xi_k|\xi_{k-1})$, womit die Wahrscheinlichkeit für das Annehmen eines bestimmten Wertes $\xi_{i,k}$ unter Vorgabe einer Eingangsgröße $u_{i,k}$ empirisch definiert ist. Zielsetzung der gewählten Vorgehensweise ist die Bereitstellung eines Erwartungswertes $E[\xi_k]$ unter Berücksichtigung aller bis zum Zeitschritt k vorhandenen Informationen. Hierzu wird durch eine lineare Interpolation über die während des Trainings aufbereiteten Daten für jede der Eingangsgrößen $V_k = [u_{1,k}, \dots, u_{n,k}, \xi_{k-1}]$ des aktuell prognostizierten Verlaufes für jeden während der Systemidentifikation genutzten Trainingsverlauf $\mathcal{D}_i = [u_i, y_i]$ der Erwartungswert $E[\xi_{i,v,k}] = E[f_i(\xi|v)|v_k]$ bestimmt:




Abbildung 49: Vorgehensweise zur Prädiktion von ξ am Beispiel eines prognostizierten Verlaufes y_P mit $v = y$ und $N_T = 2$: (a) Bestimmung von $E[\xi_{i,v,k}]$, (b) Bestimmung von $\Delta\lambda_{i,v,k}$

Anhand einer normalverteilten Gewichtung des zeitlichen Verlaufes der einzelnen Trajektorien wird für jeden Zeitschritt k und jede Eingangsgröße v ein über alle $i = 1:N_T$ gemittelter Wert $\mathcal{M}[\xi_{v,k}]$ ermittelt. Da der Erwartungswert für $\Delta\lambda_{y,k}$ nicht bekannt ist und aus der Menge der vorhandenen Datensätze empirisch bestimmt werden muss, wird für $\sigma^2_{\Delta\lambda_{v,k}}$ die empirische Varianz mit dem Korrekturfaktor $N_T - 1$ verwendet. Da die Gewichtungsfaktoren $h_{i,v,k}$ keine ganzzahligen Werte liefern müssen, wird als Korrekturfaktor der empirischen Varianz $\mathcal{V}[\xi_{v,k}]$ der Zentralwert $h_{v0,5,k}$ verwendet:

$$\mathcal{M}[\xi_{v,k}] = \frac{\sum_{i=1}^{N_T} h_{i,v,k} \cdot E[\xi_{i,v,k}]}{\sum_i h_{i,v,k}} \quad (7.21)$$

wobei:

$$h_{i,v,k} = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma^2_{\Delta\lambda,v,k}}} \cdot \exp\left(-\frac{\Delta\lambda_{i,v,k}^2}{2 \cdot \sigma^2_{\Delta\lambda,v,k}}\right) \quad (7.22)$$

$$\Delta\lambda_{i,v,k} = t_k \cdot \frac{N_T}{\sum_{i=1}^{N_T} EoL_i} - E[f_i(\lambda | v) | v_k] \quad (7.23)$$

$$\sigma^2_{\Delta\lambda,v,k} = \frac{1}{N_T - 1} \cdot \sum_{i=1}^{N_T} \left(\Delta\lambda_{i,v,k} - \frac{\sum_{i=1}^{N_T} \Delta\lambda_{i,v,k}}{N_T} \right)^2 \quad (7.24)$$

Mit der normierten Gewichtung lässt sich die Varianz $\mathcal{V}[\xi_{v,k}]$ dann analog zu (7.21) berechnen:

$$\mathcal{V}[\xi_{v,k}] = \frac{\sum_{i=1}^{N_T} h_{i,v,k} \cdot (E[\xi_{i,v,k}] - \mathcal{M}[\xi_{v,k}])^2}{\sum_{i=1}^{N_T} (h_{i,v,k}) - h_{v0,5,k}} \quad (7.25)$$

Die Zentrierung der Normalverteilung für $h_{i,v,k}$ um den Ursprung mit (7.22) bewertet anhand der Differenz der normierten Zeitpunkte $\Delta\lambda_{i,k}$ die Wahrscheinlichkeit, dass ein beobachtetes Verhalten aus der Trainingsphase zum Zeitschritt k während der Prognose wieder zu erwarten ist. Für die Prognose ist das EoL des prognostizierten Verlaufes nicht bekannt, weswegen das aktuelle λ_k in (7.23) mit einer Normierung des aktuellen Zeitpunktes t_k über alle verfügbaren Trainingsdaten bestimmt wird.

Die Ausgabewerte ξ_k und $\sigma^2_{\xi,k}$ werden durch den gewichteten Mittelwert aller Anteile für die geschätzten Erwartungswerte $\mathcal{M}[\xi_{v,k}]$ und Varianzen $\mathcal{V}[\xi_{v,k}]$ gebildet, wobei die einzelnen Gewichtungsfaktoren dem Betrag der empirischen Korrelationskoeffizienten zwischen den Eingangsgrößen und den Messwerten des jeweiligen Filterschrittes aus dem Trainingsdatensatz entsprechen. Durch diese Vorgehensweise ist sichergestellt, dass jede Eingangsgröße einen entsprechend ihrer Relevanz für die Auswirkungen auf den Messwert gewichteten Beitrag zum resultierenden Ausgabewert ξ_k und $\sigma^2_{\xi,k}$ liefert. Durch (7.26) und (7.27) werden dem Filter somit der Erwartungswert $E[\xi_k]$ und die Varianz $\sigma^2_{\xi,k}$ für den Störgrößenanteil des Prozessmodells zum Zeitschritt k bereitgestellt. Mittels (7.22) wird weiterhin gewährleistet, dass für ξ eine Normalverteilung als Vorgabe für das UKF vorliegt:

$$\xi_k = \frac{\sum_{v=1}^{N_V} r_v \cdot \mathcal{M}[\xi_{v,k}]}{\sum_{v=1}^{N_V} r_v} \quad (7.26)$$

$$\sigma^2_{\xi,k} = \frac{\sum_{v=1}^{N_V} r_v \cdot \mathcal{V}[\xi_{v,k}]}{\sum_{v=1}^{N_V} r_v} \quad (7.27)$$

wobei:

$$r_v = \left| \frac{\frac{1}{N-1} \cdot \sum_{k=1}^N (v_k - \bar{v}) \cdot (y_k - \bar{y})}{\sqrt{\frac{1}{N-1} \cdot \sum_{k=1}^N (v_k - \bar{v})^2} \cdot \sqrt{\frac{1}{N-1} \cdot \sum_{k=1}^N (y_k - \bar{y})^2}} \right| \quad (7.28)$$

5.3.2.2. Anpassung der Filtergleichungen

Allgemeingültig entspricht eine Propagierung der Schätzgrößen über mehrere Filterschritte einer Schätzung ohne vorhandene Messdaten für den Korrekturschritt der Filterung [86]. Eine Form der Implementierung von Prognosefähigkeiten für rekursive bayessche Filter ist somit die Vernachlässigung des Korrekturfaktors [87]. Wenn Messdaten eines Teilverlaufes bis zum Zeitschritt k_0 vorliegen, ergeben sich ohne datenbasierten Anteil des Prozessmodells damit für n Prädiktionsschritte folgende modifizierte Filtergleichungen des UKFs:

$$\hat{x}_{k_0+n|k_0+n-1} = \sum_{i=0}^{2n_x} w_i^{(m)} f(u_{k_0+n-1}, X_{i,k_0+n-1}) \quad (7.29)$$

$$P_{x,k_0+n|k_0+n-1} = \sum_{i=0}^{2n_x} w_i^{(c)} (X_{i,k_0+n|k_0+n-1} - \hat{x}_{k_0+n|k_0+n-1}) \cdot (X_{i,k_0+n|k_0+n-1} - \hat{x}_{k_0+n|k_0+n-1})^T + Q_x \quad (7.30)$$

$$\hat{x}_{k_0+n} = \hat{x}_{k_0+n|k_0+n-1} \quad (7.31)$$

$$P_{x,k_0+n} = P_{x,k_0+n|k_0+n-1} \quad (7.32)$$

Somit wächst die Varianz der Zustandsschätzung während der Prognosephase kontinuierlich an. Für die hybride Fehlerprognose muss zusätzlich ein datenbasierter Anteil für ξ berücksichtigt werden:

$$\hat{x}_{k_0+n|k_0+n-1} = \sum_{i=0}^{2n_x} w_i^{(m)} f(u_{k_0+n-1}, X_{i,k_0+n-1}, \xi_{k_0+n-1}) \quad (7.33)$$

$$P_{x,k_0+n|k_0+n-1} = P_{x,k_0+n|k_0+n-1} + Q_{\xi,k_0+n-1} \quad (7.34)$$

Die Filterauslegung für den Prognoseanteil benötigt die Störgrößenschätzung nicht, da die Prädiktion der Störgröße ξ durch das Datenmodul $g(u, \xi)$ realisiert wird.

Somit wird für die Prognosephase die Implementierung des UKFs als reiner Zustandsschätzer mit explizitem Prozessmodell entsprechend [Anhang A](#) verwendet. Da der datenbasierte Anteil bei der

Schätzaufgabe nicht als Zufallsvariable berücksichtigt wird, müssen die zeitvarianten Modellanteile $E[\xi_k]$ und $\sigma_{\xi,k}^2$ aus den vorhandenen Datensätzen abgeleitet werden²³:

$$\xi_{k_0+n} = g(u_{k_0+n-1}, \xi_{k_0+n-1}) \quad (7.35)$$

$$Q_{\xi,k_0+n} = \left(\frac{\partial f}{\partial \xi} \right)^2 \cdot \sigma_{\xi,k_0+n}^2 + 2 \cdot \frac{\partial f}{\partial \xi} \cdot \frac{\partial f}{\partial x} \cdot \text{cov}(\xi_{k_0+n}, x_{k_0+n}) \quad (7.36)$$

Durch die partiellen Ableitungen wird die Sensitivität des Systemmodells gegenüber $g(u, \xi)$ und der Dynamik des Modellzustandes x berücksichtigt. Bei Bedarf können zur besseren Abbildung von Nichtlinearitäten höhere Terme einer Taylorreihenentwicklung für die Annäherung der Modellsensitivitäten hinzugefügt werden [106]. Die Kovarianz $\text{cov}(\xi, x)$ kann durch Kenntnis der statistischen Zusammenhänge zwischen ξ und x , die aus der Herleitung des Datenanteils $g(u, \xi)$ bekannt sind, gebildet werden. Dieser Beitrag ist erforderlich, da die Störgrößen ξ und Modellzustände x nicht als unkorreliert, bzw. mit vernachlässigbarer Kovarianz angenommen werden können.

Die restlichen Filtergleichungen bleiben unverändert. Durch mehrmaliges Iterieren des durch (7.29)-(7.36) angepassten UKFs als Zustandsschätzer lässt sich somit die hybride Fehlerprognose implementieren und der Verlauf der ersten beiden statistischen Momente eines Merkmals unter Berücksichtigung von statistisch konsistenter Störgrößennachbildung beliebig viele Schritte propagieren.

Für die Validierung des beschriebenen Ansatzes wurde nachfolgendes Systemmodell mit datenbasiertem Anteil verwendet:

$$x_k = 0,15 \cdot u_{k-1} + 0,5 \cdot \sqrt{\xi_{k-1} \cdot x_{k-1}} + x_{k-1} + v_{k-1}$$

$$y_k = 0,25 \cdot x_k + w_k$$

mit:

u_k = Lineare Reihe mit $U = [1, 2, 3, \dots, 100]$

ξ_k = Normalverteilte Zufallsvariablen ($\mu_{\xi,i} \in [2, 75; 5]$, $\sigma_{\xi,i}^2 \in [10^{-1}; 1]$)

v_k = Normalverteilte Zufallsvariable ($\mu_v = 0$; $\sigma_v^2 = 10^{-2}$)

w_k = Normalverteilte Zufallsvariable ($\mu_w = 0$; $\sigma_w^2 = 10^{-2}$)

Es wurden 100 Einzelverläufe $y_{i,k}$ mit 100 zufällig generierten Datensätzen ξ_i simuliert und die zugehörigen Verläufe des Erwartungswertes $E[y_{i,k}]$ und die $\pm 3 \cdot \sigma_{y_{i,k}}$ Bereiche empirisch bestimmt. Im Vergleich dazu sind das Ergebnis der hybriden Prognose durch den Erwartungswert $E[y_{p,k}]$ und die $\pm 3 \cdot \sigma_{y_{p,k}}$ Bereiche sowie der jeweilige prozentuale Fehler dargestellt:

²³ Die Implementierung für Q_ξ ist aus der in [106] beschriebenen Vorgehensweise für die Berücksichtigung von Unsicherheiten korrelierter Messgrößen abgeleitet worden.




Abbildung 50: Hybride Prognose im Vergleich zu 100 zufällig generierten individuellen Verläufen:

(a) Verlauf der Erwartungswerte und 3σ Vertrauensbereiche, (b) Abweichung zwischen Erwartungswerten (Δy), $+3\sigma$ Bereichen (Δy_{UL}) und -3σ Bereichen (Δy_{LL})

Das Ergebnis zeigt für normalverteilte Größen eine gute Übereinstimmung für die Propagierung der ersten beiden statistischen Momente mittels der hybriden Prognosefunktion. Die exponentiell abnehmende Abweichung lässt auf einen vernachlässigbaren systematischen Fehler schließen, der aus der Anzahl der Datensätze und den daraus abgeleiteten statistischen Momenten resultieren kann.

Der datenbasierte Anteil für den GP-UKF-Ansatz besteht aus mehreren Verteilungsfunktionen $f(\xi|u_i)$, weswegen (7.36) entsprechend zu erweitern ist (Vorgehensweise zur Bestimmung der Kovarianzterme $C[\xi, x]$ analog zu (7.25) über alle $i = 1:N_T$ Testläufe):

$$Q_{\xi, k} = \frac{\sum_{v=1}^{N_V} r_v \cdot \left(\left(\frac{\partial f}{\partial \xi} \right)^2 \cdot \mathcal{V}[\xi_{v, k}] + 2 \cdot \frac{\partial f}{\partial \xi} \cdot \frac{\partial f}{\partial x} \cdot C[\xi_{v, k}, f(x | \xi_{v, k})] \right)}{\sum_{v=1}^{N_V} r_v} \quad (7.37)$$

Zum Nachweis der vollständigen Implementierung ist ein generisches Degradierungsverhalten simuliert und ein zufällig ausgewählter Verlauf prognostiziert worden. Als Modell für die Trainingsverläufe $Y = [y_1, \dots, y_n]$ wurde eine geometrische Brownsche Bewegung verwendet:

$$y_k = \exp \left[\left(\mu - \frac{\sigma^2}{2} \right) \cdot t_k + \sigma \cdot W_k \right]$$

wobei:

$$W_k = W_k - W_0 \sim N(0, k)$$

mit:

- μ = 1 (entspricht dem Driftparameter des Prozesses)
- W_0 = 0 (entspricht dem Startwert des Wiener Prozesses)
- σ^2 = 0,1 (entspricht der Volatilität des Prozesses)

Es wurden 10 individuelle Trajektorien als Trainingsdatensatz für die modellbasierte Systemidentifikation simuliert:




Abbildung 51: Trainingsdatensatz für Modellidentifikation mit 10 Einzeltrajektorien

Die Zielsetzung der Modellidentifikation ist die Herleitung einer Beschreibung des Verlaufes von y_k als Funktion der Simulationszeit t_k und des Wertes vom vorherigen Simulationsschritt y_{k-1} . Die Messgleichung $h(x)$ wurde als bekannt vorausgesetzt ($y_k = h(x_k) = x_k$). Der Verlauf der Modellidentifikation über 50 Generationen sowie die Störgrößenschätzung sind in **Abbildung 52** dargestellt:




Abbildung 52: Modellidentifikation für die Prognose: (a) Fitnessverlauf der Systemidentifikation, (b) Schätzwert für Störgröße ξ aller 10 Verläufe

Zur Demonstration der Prognosefähigkeiten ist das identifizierte Systemmodell mit den aufbereiteten Datenmodulen verwendet worden, um für eine zufällig ausgewählte Trajektorie des Datensatzes mit $t_0 = 0,25 \cdot \lambda$ den Verlauf des Erwartungswertes y_P und die $\pm 3 \cdot \sigma_{y,P}$ Bereiche zu prognostizieren (s. **Abbildung 53**). Das Ergebnis der Modellidentifikation ermöglicht für die ausgewählte Trajektorie bereits zu einem frühen Zeitpunkt eine zuverlässige Prognose. Die Vertrauensbereiche bilden die Streuung des verwendeten Trainingsdatensatzes ab und ermöglichen so auch für die anderen Trajektorien eine Prognose, bei der sowohl der jeweilige Verlauf als auch der finale Wert innerhalb der Verteilungen $p(CI_k|u_k, CI_{k-1})$ und $p(EoP|CI)$ liegen. Die PoF nach (7.7) beinhaltet sowohl die Varianz der Werte zum Zeitpunkt $\lambda_i = 1$ als auch die der prognostizierten Verteilung $p(CI_k|u_k, CI_{k-1})$, wodurch sich für dieses Beispiel zur Vermeidung von Fehlern im Betrieb die Notwendigkeit ergeben würde, den Austausch mit $PoF \leq 75\%$ durchzuführen.




Abbildung 53: Prognose für ausgewählten Verlauf: (a) Prognostizierte Störgröße ξ_P , (b) Prognostizierter Verlauf y_P mit Vertrauensbereichen und PoF

Der Verlauf der prognostizierten Störgröße ξ_P ermöglicht bis zum 75en Prädiktionsschritt (entspricht $\lambda \approx 1$) eine zuverlässige Rekonstruktion aus dem vorhandenen Datensatz. Für die nachfolgenden Prädiktionsschritte verlassen $t_{P,k}$ und $y_{P,k}$ den Wertebereich der Datenmodule, womit der Beitrag zur Prädiktion von ξ_P ein konstanter Wert ist und lediglich der Anteil durch $\xi_{P,k-1}$ noch einige Schritte einen variablen Anteil liefert. Durch die Mittelwertbildung mit (7.26) verläuft $\xi_{P,75:89}$ dadurch annähernd konstant.

5.3.3. Erweiterung zum Multiple-Model-Ansatz

Zur Steigerung der lokalen Gültigkeit der Prognosemodule wurde der in § 4.5 beschriebene hybride Ansatz erweitert um auch Prognose zu ermöglichen. Neben den in § 4.5.3 hergeleiteten Bewertungskriterien für Prognose mit multiplen Modellen (s. § 5.3.1), ist zusätzlich eine geeignete Kooperationsstrategie für die Prädiktionsphase aufgestellt worden:

Während in der Identifikationsphase eine SM-Strategie verwendet werden musste, um die Herleitung der gewünschten Modellstrukturen zu ermöglichen, ist in der Prognosephase zum Zeitschritt k der Zustand und Modellausgabewert für den nächsten Zeitschritt $k+1$ unbekannt und der mögliche Beitrag aller Modelle zu berücksichtigen. Hierfür wird ein CMM-Ansatz verfolgt, der nach jedem Prädiktionsschritt einen fusionierten Modellzustand \bar{x} und die Fehlerkovarianzmatrix \bar{P}_x bereitstellt:

$$\bar{x}_k = \Phi(\hat{x}_{1,k}, \dots, \hat{x}_{M,k}) \quad (7.38)$$

$$\bar{P}_{x,k} = \Phi(\bar{P}_{x1,k}, \dots, \bar{P}_{xM,k}) \quad (7.39)$$

wobei:

$$\hat{x}_{i,k} = f_i(u_{k-1}, \hat{x}_{i,k-1}, \xi_{i,k}) \quad (7.40)$$

$$\xi_{i,k} = g_i(u_{k-1}, \xi_{i,k-1}) \quad (7.41)$$

$$\bar{P}_{xi,k} = P_{xi,k} + (\bar{x}_k - \hat{x}_{i,k}) \cdot (\bar{x}_k - \hat{x}_{i,k})^T \quad (7.42)$$

mit:

M = Anzahl der verwendeten Modelle

Die Kooperationsstrategie zur Fusion der unterschiedlichen Filter wird nach [92] durch die Funktion $\Phi(\cdot)$ beschrieben:

$$\Phi(x_{1:M,k}) = \sum_{i=1}^M \mu_{i,k} \cdot x_{i,k} \quad (7.43)$$

wobei:

$$\mu_{i,k} = \frac{L_{i,k} \cdot \hat{\mu}_{i,k}}{\sum_{j=1}^M L_{j,k} \cdot \hat{\mu}_{j,k}} \quad (7.44)$$

$$\hat{\mu}_{i,k} = \sum_{j=1}^M H_{i|j} \cdot \mu_{j,k-1} \quad (7.45)$$

mit:

$H_{i|j}$ = Wahrscheinlichkeit mit der ein Wechsel von Modell j auf Modell i stattfindet

$L_{i,k}$ = Wahrscheinlichkeit für Modell i zum Zeitpunkt k

Der Ansatz der empirischen Transitionsmatrix H folgt der in § 4.5.1.2 beschriebenen CMM-Theorie, um durch die Matrixelemente die Wahrscheinlichkeit für einen Modellübergang zu beschreiben. Für das untersuchte GP-UKF-Konzept wird H anders als in [92] nicht vorgegeben sondern durch die Systemidentifikation empirisch bestimmt und bleibt in der Prognosephase konstant:

$$H_{i|j} = \frac{\sum_{i=1}^N [\{f(u_k, y_k) \in c_i\} \wedge \{f(u_{k-1}, y_{k-1}) \in c_j\}]}{N} \quad (7.46)$$

mit:

c_i = Datenklassifikation Bereich i zur Modellauswahl für hybride Systemidentifikation

c_j = Datenklassifikation Bereich j zur Modellauswahl für hybride Systemidentifikation

N = Anzahl der Messpunkte für Systemidentifikation

Äquivalent zum IMM-Ansatz wird für den Filterschritt $k+1$ durch eine gewichtete Reinitialisierung aller Filter die Anzahl der Hypothesen reduziert:

$$\mu_{i|j,k+1} = \frac{H_{i|j} \cdot \mu_{j,k}}{\hat{\mu}_{i,k+1}} \quad (7.47)$$

$$\bar{x}_{i,k|k} = \sum_{j=1}^M \mu_{i|j,k+1} \cdot \hat{x}_{j,k} \quad (7.48)$$

$$\bar{P}_{xi,k|k} = \sum_{j=1}^M \mu_{i|j,k+1} \cdot [\bar{P}_{xj,k} + (\bar{x}_{i,k|k} - \hat{x}_{j,k}) \cdot (\bar{x}_{i,k|k} - \hat{x}_{j,k})^T] \quad (7.49)$$

mit:

$\bar{x}_{i,k|k}$ = Reinitialisierter Zustand Modell i zum Zeitschritt $k+1$

$\bar{P}_{xi,k|k}$ = Reinitialisierte Fehlerkovarianzmatrix Modell i zum Zeitschritt $k+1$

Ohne Verwendung von (7.48) und (7.49) müssten alle theoretisch möglichen Einzelprognosen und deren Kombinationen an Modelltransitionen gesondert betrachtet und abschließend fusioniert werden, womit die Anzahl der Einzellösungen für M Modelle und k Zeitschritte auf M^k Möglichkeiten ansteigen würde [92].

Die Bestimmung der Wahrscheinlichkeiten für die Modellauswahl $L_{i,k}$ von Modell i zum Zeitschritt k basiert ebenfalls auf einem datenbasierten Anteil $p(m_{i,k}|v_k)$ für jede der genutzten Eingangsgrößen $V = [u_{1,k}, \dots, u_{n,k}, \xi_{i,k-1,k}, y_{k-1}]$. Die Verteilung zur Auswahl eines Modells unter Kenntnis des jeweiligen Eingangsvektors $p(m_{i,k}|v_k)$ wird während der Systemidentifikation mittels Bayes Theorem für bedingte Wahrscheinlichkeiten aus dem Trainingsdatenanteil abgeleitet [115]:

$$p(m_i | v) = \frac{p(v | m_i) \cdot p(m_i)}{p(v)} = \frac{p(m_i \cap v)}{p(v)} \quad (7.50)$$

Die beschriebene Vorgehensweise zur Herleitung der Modellgewichtungen ist in Abbildung 54 beispielhaft für zwei Modelle mit einem Datensatz bestehend aus 1000 unabhängigen Zufallszahlen einer Exponentialverteilung mit Erwartungswert $\mu = 10$ dargestellt. Das Auswahlkriterium der zwei Modelle wird durch den Erwartungswert mit $p(m_1|u < \mu) > 0$ und $p(m_2|u \geq \mu) > 0$ definiert:

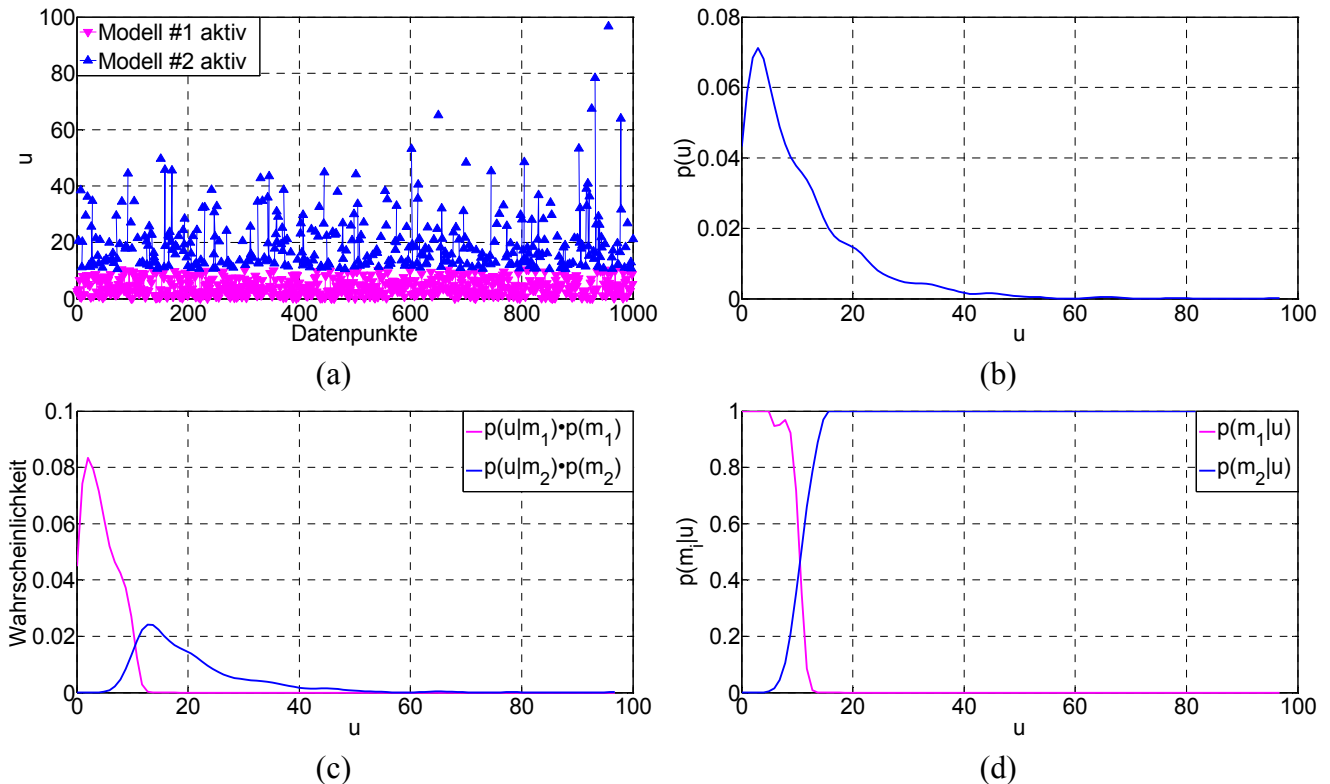


Abbildung 54: Vorgehensweise zur Bestimmung der Wahrscheinlichkeiten zur Modellauswahl für die Prognose mit *Multiple-Model-Ansatz*: (a) Datenklassifikation Eingangsgröße u mit $c_1 = [-\infty, 10[$ und $c_2 = [10, \infty]$, (b) Bestimmung der Dichtefunktion $p(u)$, (c) Schnittmengen $p(u \cap m_i)$, (d) Wahrscheinlichkeiten zur Modellauswahl $p(m_i|u)$

Die Bestimmung eines einheitlichen Wertes zur Modellauswahl erfolgt analog zu (7.26)-(7.28) durch die Gewichtung mit dem Betrag der Korrelationskoeffizienten zwischen der jeweiligen Eingangsgröße und dem Modellausgabewert über alle Eingangsgrößen $V = [u_{1,k}, \dots, u_{n,k}, \xi_{i,k-1,k}, y_{k-1}]$:

$$L_{i,k} = \frac{\sum_{v=1}^{N_V} r_v \cdot p(m_i | v_k)}{\sum_{v=1}^{N_V} r_v} \quad (7.51)$$

Unter Berücksichtigung einer gemeinsamen Beobachtungsfunktion $h(u, x)$ zur Abbildung der Schadensgröße x_k auf den aus der Diagnosefunktion bekannten CI_k , kann durch den Prädiktionsanteil des UKFs sowie (7.38) und (7.39) auch für die Prognosephase ein Ausdruck für den Modellausgabewert y_k und die entsprechende Kovarianz $P_{y,k}$ hergeleitet werden (n_x , λ und $w_i^{(c)}$ entsprechend der Implementierungsform als Zustandsschätzer aus [Anhang A](#))²⁴:

$$\bar{y}_k = \sum_{i=0}^{2n_x} w_i^{(m)} \bar{Y}_{i,k} \quad (7.52)$$

$$\bar{P}_{y,k} = \sum_{i=0}^{2n_x} w_i^{(c)} (\bar{Y}_{i,k} - \bar{y}_k) \cdot (\bar{Y}_{i,k} - \bar{y}_k)^T + R_y \quad (7.53)$$

wobei: $\bar{Y}_k = h(\bar{X}_k, u_k) \quad (7.54)$

$$\bar{X}_k = \left[\bar{x}_k, \bar{x}_k + \sqrt{(n_x + \lambda) \cdot \bar{P}_{x,k}}, \bar{x}_k - \sqrt{(n_x + \lambda) \cdot \bar{P}_{x,k}} \right] \quad (7.55)$$

Um die Komplexität der Systemidentifikation zu reduzieren wird die Funktion zur Messgrößenbeobachtung $h(u, x)$ als bekannt voraus gesetzt und der Modellausgabewert $y = h(u, x)$ als der zu prognostizierende CI verwendet.

Wenn der maximal zulässige Wert der Schadensgröße oder die Verteilung $p(x_{max})$ bekannt sind, kann die Prognose auch unter Vernachlässigung des CI durch den Verlauf $p(x_k | u_{k-1}, x_{k-1})$ vorgenommen werden. Da für einen Großteil realer Anwendungen jedoch die Bestimmung des Zustandes nicht direkt durch die Messung der Schadensgröße sondern über den Verlauf des CI erfolgt, wird der Ansatz entsprechend (7.52)-(7.55) genutzt werden müssen.

Wenn der funktionale Zusammenhang zwischen der Schadensgröße und dem CI nicht bekannt ist und der Schaden auch nicht direkt gemessen wird, entspricht die Schätzung des Zustandes x der Bestimmung des CI und die Beobachtungsfunktion $h(u, x)$ bildet den Zustand x direkt auf den CI ab ($CI = y = h(u, x) = x$). Gleiches gilt für unterschiedliche Beobachtungsfunktionen $h_i(u, x)$ verschiedener Filter $i = 1:M$, für die dann keine Fusion des Modellausgabewertes möglich ist.

²⁴ Die Bestimmung des fusionierten Modellausgabewertes kann auch mittels eines beliebigen anderen Ansatzes vorgenommen werden, der unter Berücksichtigung einer bekannten Modellgleichung den Erwartungswert y_k und die Kovarianz $P_{y,k}$ bestimmt.

Für die geometrische Brownsche Bewegung aus § 5.3.2.2 ist mit den getroffenen Annahmen ein *Multiple-Model-Ansatz* durch den GP-UKF hergeleitet und getestet worden. Als Auswahlkriterium zur Datenklassifikation diene der Wert der Modellausgabegröße y , mit $c_1 = [-\infty, 2[$ und $c_2 = [2, \infty]$.

Zur Veranschaulichung sind die Verläufe der Eingangsgrößen, der daraus resultierenden Kriterien zur Modellauswahl und das Ergebnis der Prognose in Abbildung 55 dargestellt:

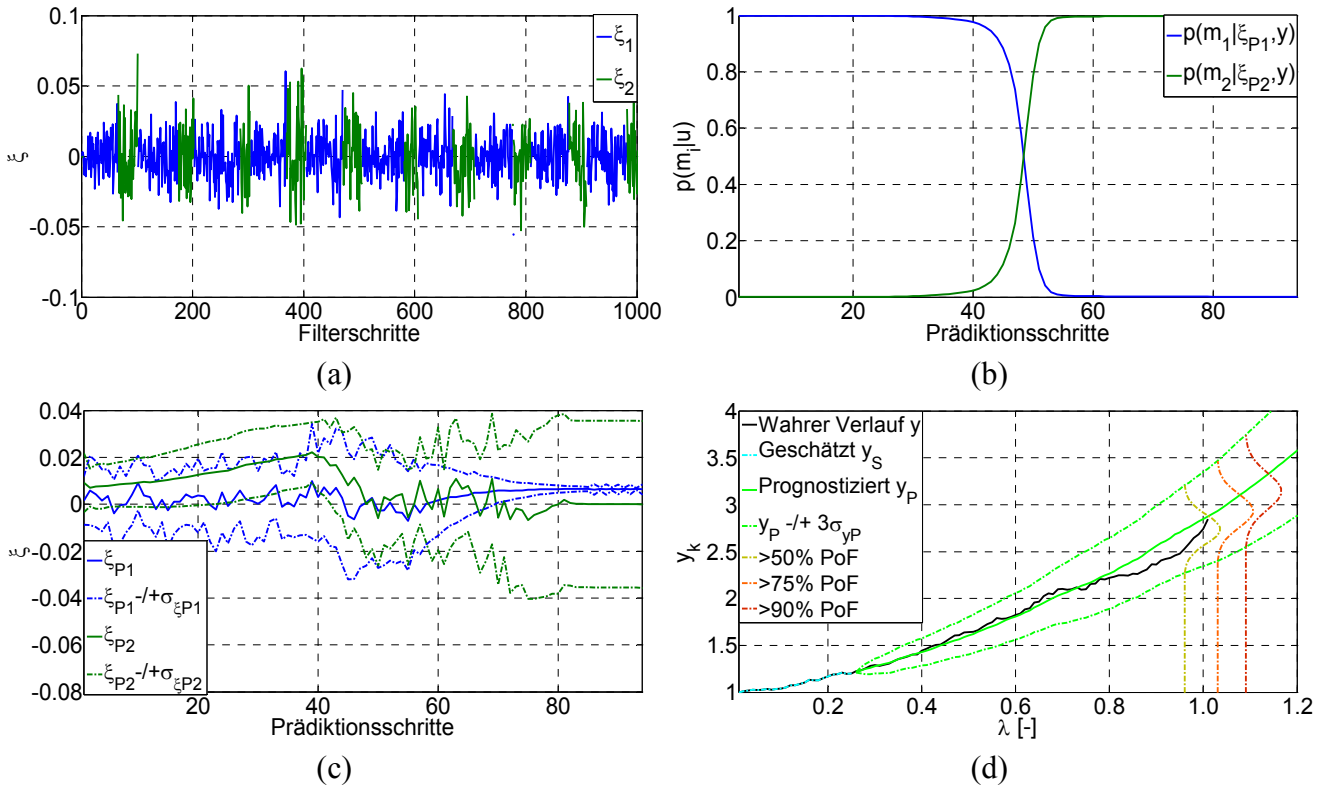


Abbildung 55: Prognose mit *Multiple-Model-Ansatz*: (a) Geschätzte Störgröße ξ_i aus Trainingsdatensatz, (b) Modellgewichtung als Funktion der Modelleingangsgrößen (c) Prognostizierte Störgrößen ξ_{Pi} , (d) Prognostizierter Verlauf y_P

Durch die beschriebene Vorgehensweise lässt sich der gewählte Datenbereich zur Datenklassifikation als Modellauswahlkriterium beliebig hoch auflösen und die Prognose mit einer beliebigen Anzahl an lokal optimierten Modellen durchführen. Hierfür muss lediglich die Anzahl der Datenpunkte und Kriterien zur Klassifikation entsprechend erhöht werden. Ob durch eine höhere Auflösung auch eine Verbesserung des Ergebnisses erreicht werden kann, muss anwendungsfallspezifisch analysiert und entschieden werden.

5.3.4. Globale Korrektur zur Verbesserung der Prognosegüte

Ausgehend von der nachträglichen Bewertung der Prognosegüte ist in [97] ein Verfahren zur datenbasierten Optimierung der Prognosequalität entwickelt worden. Dieses als „*Outer Loop Correction*“ oder „*Global Correction Factor*“ bekannte Verfahren bestimmt empirisch einen Korrekturfaktor durch Kenntnis des Prognosefehlers ε_p als Funktion des Startpunktes der Prognose t_0 :




Abbildung 56: Herleitung des Korrekturfaktors für die globale Korrektur der Prognosequalität

Durch die Verwendung eines normierten Startpunktes der Prognose λ_{p0} kann der Korrekturfaktor unabhängig von dem zeitlichen Verlauf einer Degradierung genutzt werden. Dieser Aspekt ist relevant, da hiermit der Einfluss der Nutzungsbedingungen und Materialvariabilität, die von Verlauf zu Verlauf variieren können, bei der Betrachtung des Korrekturfaktors korrigiert wird. Da während der Prognose das wahre EoL nicht bekannt ist, wird für die Implementierung des Korrekturfaktors der aktuelle Wert $\lambda_{p0,k}$ mit dem aktuellen Startpunkt der Prognose $t_{p0,k}$ und dem Erwartungswert der normierten Ausfallzeitpunkte bestimmt:

$$\lambda_{p0,k} = t_{p0,k} \cdot \frac{N_T}{\sum_{i=1}^{N_T} EoL_i} \quad (7.56)$$

Der dann für die globale Korrektur verwendete Wert kann entweder durch den Erwartungswert $E[\varepsilon_P(\lambda_{p0})]$ oder Zentralwert $\varepsilon_P(\lambda_{p0})_{0,5}$ bestimmt werden. Bei Verwendung des Zentralwertes werden überdurchschnittlich große Fehler in den vorhergehenden Prognosen nicht berücksichtigt, während der Erwartungswert alle gesammelten Prognoseergebnisse in der Korrektur gleichermaßen gewichtet. Der Einfluss ist vergleichbar mit dem MMSE- oder MAP-Kriterium (s. § 4.5.1), wobei $E[\varepsilon_P(\lambda_{p0})]$ das MMSE-Kriterium und $\varepsilon_P(\lambda_{p0})_{0,5}$ das MAP-Kriterium des globalen Korrekturfaktors annähert.

Die Korrektur der statistischen Eigenschaften der Verteilung $p(EoP|CI)$ wird schließlich mittels (7.57) und (7.58) und wahlweise unter Verwendung von $E[\varepsilon_P(\lambda_{p0})]$ oder $\varepsilon_P(\lambda_{p0})_{0,5}$ vorgenommen:

$$E[p(EoP_{Korr} | CI)]_{i,k} = E[p(EoP | CI)]_{i,k} \cdot \left(1 + \frac{E[\varepsilon_{Pi}(\lambda_{p0,k})]}{EoL_i}\right)^{-1} \quad (7.57)$$

$$\sigma_{EoP_{Korr}i,k} = \sigma_{EoPi,k} \cdot \left(1 + \frac{E[\varepsilon_{Pi}(\lambda_{p0,k})]}{EoL_i}\right)^{-1} \quad (7.58)$$

5.4. Implementierung des GP-UKF Prognosekonzeptes

Für die Implementierung des GP-UKF Prognoseansatzes wird die Systemidentifikation darauf ausgerichtet, für jedes der $i = 1:M$ Modelle die Funktion für das Derivat $f_i(u, x_i, \xi_i)$ der Schadensgröße x_i zu identifizieren:

$$\hat{x}_{i,k|k-1} = f(u_{k-1}, x_{i,k-1}, \xi_{i,k}) = x_{i,k-1} + f_i(u_{k-1}, x_{i,k-1}, g_i(u_{k-1}, \xi_{i,k-1})) \cdot \Delta t \quad (7.59)$$

$$CI_{i,k} = h(u_k, \hat{x}_{i,k|k-1}) \quad (7.60)$$

Die Funktion $h(u, x)$ wird als einheitlich und bekannt vorausgesetzt, die Schrittweite Δt ist konstant und die Aufgabe der *Genetischen Programmierung* besteht in der iterativen Optimierung der Funktionen $f_i(u, x_i, \xi_i)$.

Die Vorgehensweise zur Nutzung des Derivats als Schadensmodell entspricht den bekannten Ansätzen für Ermüdungs- und Verschleißprozesse [116], [117]. Der CI wird durch die Messgleichung $h(u, x)$ aus der Schadensgröße x hergeleitet. Somit wird sich eine Änderung in der Schadensgröße auch in einer Änderung des CI ausdrücken und entsprechend der Zielsetzung eine Funktion für das Derivat des Schadensverlaufes zu identifizieren, werden ausgewählte Perzentilen des Derivats des CIs aus den verfügbaren Trainingsdaten als Indikator für die Datenklassifikation genutzt:

$$c_i = f_i\left(\frac{\partial CI}{\partial t}\right) \quad (7.61)$$

$$\text{wobei:} \quad f_i\left(\frac{\partial CI}{\partial t}\right) = \left[p_{0i} \cdot \frac{\partial p\left(\frac{\partial CI}{\partial t}\right)}{\partial CI}, p_{ei} \cdot \frac{\partial p\left(\frac{\partial CI}{\partial t}\right)}{\partial CI} \right] \quad (7.62)$$

$$p_i \in \mathfrak{R} \mid 0 \leq p_{0i} \leq p_{ei}$$

Entsprechend der Vorgehensweise zur Datenklassifikation und Systemidentifikation, einen Ausdruck für das Derivat des CI herzuleiten, muss auch das Kriterium zur Relevanzgewichtung der Modelleingangsgrößen nach (7.28) angepasst werden:

$$r_v = \left| \frac{\frac{1}{N-1} \cdot \sum_{k=1}^N (v_k - \bar{v}) \cdot (y'_k - \bar{y}')}{\sqrt{\frac{1}{N-1} \cdot \sum_{k=1}^N (v_k - \bar{v})^2} \cdot \sqrt{\frac{1}{N-1} \cdot \sum_{k=1}^N (y'_k - \bar{y}')^2}} \right| \quad (7.63)$$

$$\text{wobei:} \quad y' = \frac{\partial CI}{\partial t} \quad (7.64)$$

Als gesamtheitliches Konzept zur Identifikation von Prognosemodulen für beliebige Degradierungsprozesse ergibt sich damit folgende Erweiterung des funktionalen Ablaufs der in § 4.5.3 beschriebenen modellbasierten Systemidentifikation:

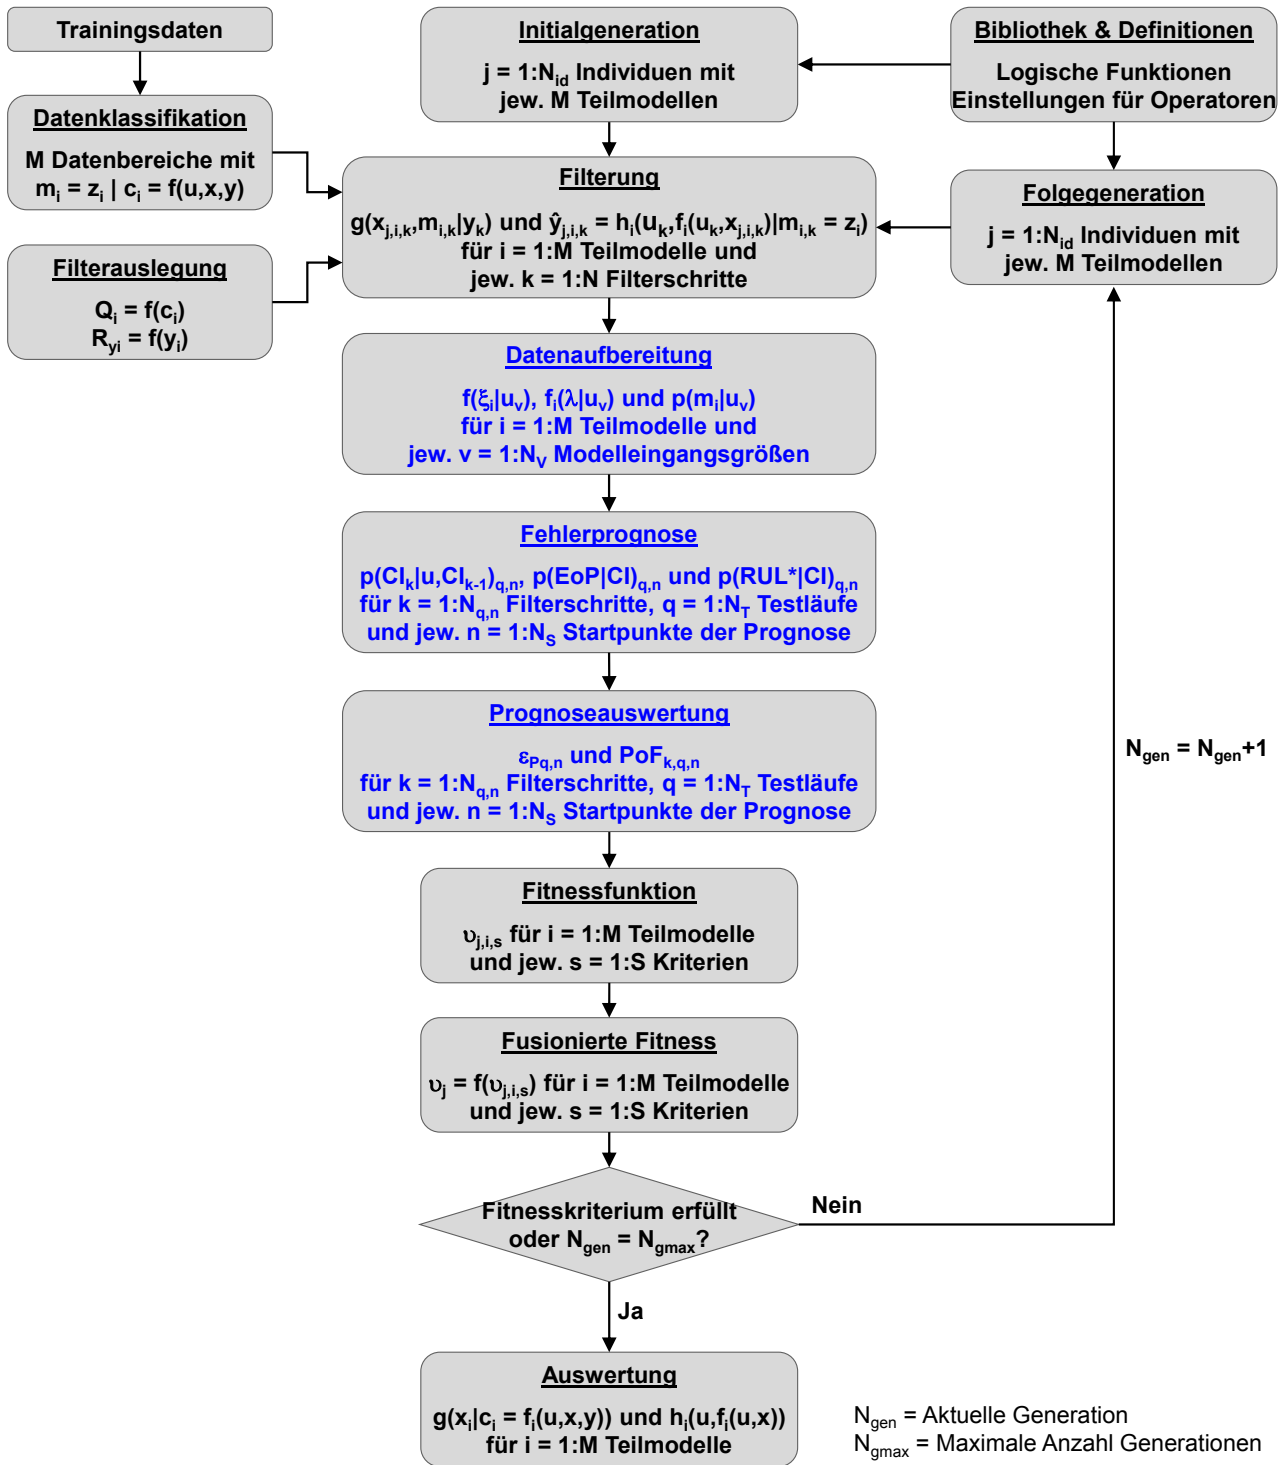


Abbildung 57: Implementierung der hybriden Fehlerprognose durch den vollständigen GP-UKF-Ansatz inklusive Auswertung der Prognosefähigkeiten zur Bewertung der Systemidentifikation

Durch die integrierte Nutzung der Prognosegüte als Bewertungskriterium für die *Genetische Programmierung* konvergiert die Systemidentifikation zu einem optimierten Degradierungsmodell für die Fehlerprognose und bei Bereitstellung von zusätzlichen Datensätzen ebenfalls zu einer optimierten Datenbasis zur Prädiktion von ξ , der Modellauswahl für die IMM-basierte Prognose und den globalen Korrekturfaktor. Die Auflösung der Korrekturfunktion kann hierbei beliebig hoch gewählt

werden, um während der Nutzung einen auf den jeweiligen Startpunkt der Prognose optimierten Korrekturfaktor bestimmen zu können. Die Anzahl der Modelle kann ebenfalls beliebig hoch gewählt werden, um die lokale Gültigkeit für den ausgewählten Datenklassifikationsansatz zu erhöhen. Die rechenintensive modellbasierte Systemidentifikation bedarf vor der Nutzungsphase lediglich einer Iteration mit der vorgegebenen Anzahl an Individuen und Generationen. Für die Anwendung zur Fehlerprognose ist der Rechenbedarf nicht wesentlich größer als für herkömmliche modellbasierte Ansätze, bietet jedoch durch den datenbasierten Anteil für die Prädiktion von ξ und der dynamischen Modellauswahl $p(m|u)$ eine besser an das jeweilige Szenario angepasste Lösung als ein rein modellbasierter Ansatz. Gleichmaßen ist die Modellstruktur für den untersuchten Degradierungstyp allgemeingültig und kann auch außerhalb des Trainingsdatenbereiches verwendet werden, wobei dann lediglich für die Modellgewichtung und Prädiktion der Störgröße ξ konstante Werte mit reduzierter Aussagekraft für die Prognose verfügbar sind.

Um das Steigerungspotential von operativen Merkmalen durch die Leistungsfähigkeit der Prognose zu analysieren, sind die beiden Parameter θ_P und γ_P zur Vorgabe der Prognosequalität für das MMDL aus den Ergebnissen der Verifikation des Prognosekonzeptes abzuleiten.

Die relative Genauigkeit θ_P wird durch den über alle Testläufe gemittelten MAPE bestimmt:

$$\theta_P = 1 - \frac{MAPE}{100} \quad (7.65)$$

Zur Herleitung der relativen Präzision γ_P können ausgewählte Vertrauensbereiche der Verteilung $p(EoP|CI)$ und den daraus abgeleiteten statistischen Momenten von RUL^* verwendet werden:

$$\gamma_P = \sum_{i=1}^{N_T} \left(\frac{\sum_{j=1}^{N_S} \left(\frac{E[RUL^*]_{i,j} - RULPI^*_{i,j} \cdot w(\lambda_{i,j})}{E[RUL^*]_{i,j}} \right)}{\sum_{j=1}^{N_S} w(\lambda_{i,j})} \right) \cdot \frac{1}{N_T} \quad (7.66)$$

mit:

$RULPI^*_{i,j}$ = Verbleibende Nutzungsdauer für 1% Perzentile der Verteilung $p(RUL^*_{i,i})$

Mit (7.65) und (7.66) stehen aus dem Ergebnis der Verifikation die beiden benötigten Parameter zur Verfügung, um mittels des MMDLs das operative Potential des Prognoseansatzes zu bewerten. Durch die Wahl des Parameters $RULPI^*$ wird der Einfluss eines Austausches zur Erhöhung der Betriebssicherheit berücksichtigt.

6. Analyse der hybriden Fehlerprognose

Nachdem in den vorhergehenden Kapiteln die Anforderungen definiert, das allgemeine Konzept und detaillierte Design hergeleitet und die Integration auf Modul- und Systemebene nachgewiesen wurde, soll nun die Leistungsfähigkeit der hybriden Fehlerprognose bewertet werden. Der hierfür vorgesehene Ansatz besteht aus einer umfassenden Auswertung der verfügbaren synthetischen und experimentellen Daten, um schließlich mittels einer Priorisierung einzelner Bewertungskriterien sowohl die Leistungsfähigkeit des GP-UKFs zu bewerten als auch einen Vergleich mit einem existierenden hybriden Konzept aus dem Bereich der hybriden Fehlerprognose vorzunehmen.

Um eine Vergleichbarkeit mit dem aktuellen Stand der Technik zu ermöglichen, wird hierzu der in [52] beschriebene hybride Ansatz (UKF-GAP) bewertet und mit den Ergebnissen des GP-UKFs verglichen. Der UKF-GAP basiert auf einer Kombination aus dem Gauß-Prozess für parameterfreie Regressionsanalysen, dem UKF als Zustandsschätzer und zur Prädiktion eines CI mit nichtlinearen Schadensmodellen sowie einem IMM-Ansatz, um eine breite Menge an verfügbaren Trainingsdatensätzen nutzen zu können. Damit besteht eine Ähnlichkeit zum hier untersuchten GP-UKF-Ansatz, jedoch stellen die Maßnahmen zur Nutzung der Trainingsdaten einen grundlegend anderen Ansatz dar, womit der Vergleich zum GP-UKF geeignet ist, um dessen Potential auch relativ zu anderen Arbeiten betrachten zu können.

Die Bewertungskriterien wurden aus Vorarbeiten nach [118] abgeleitet und für ausgewählte Eigenschaften erweitert, um die Fähigkeiten der Prognose umfassend beurteilen zu können.

Zur Unterstützung der Verifikation sind eigene Simulationsmodelle für den Verlauf eines CI unter Berücksichtigung von stochastischen, nicht messbaren Einflüssen und messbaren äußeren Lasten aufgestellt worden. Um die Aussage der Verifikation weitestgehend verallgemeinern zu können, wurde hierbei darauf geachtet, mit den simulierten Daten ein möglichst breites Spektrum an Degradierungsverläufen abzudecken. Zusätzlich wurden experimentelle Tests mit einem luftfahrttauglichen Lüfter durchgeführt und das Vibrationsspektrum der degradierenden Kugellager verwendet, um auch mit realen Daten den Nachweis der Prognosefähigkeit zu erbringen.

Die Vorgehensweise zur Herleitung der Bewertungskriterien, der Aufbereitung und Nutzung der Trainingsdaten sowie die Ergebnisse der Verifikation werden im Folgenden erläutert.

6.1. Kriterien zur Bewertung der Prognosefähigkeit

Nach [118] gliedert sich die Bewertung von Prognoseansätzen in drei Kategorien:

- K1.Prognoseleistungsfähigkeit
- K2.Benötigte Rechenleistung
- K3.Kosten-Nutzen-Analyse

Das Ziel der Verifikation des GP-UKF-Ansatzes ist der Nachweis der Prognoseleistungsfähigkeit. Die benötigte Rechenleistung wird durch die Auslegungsanforderung, dass keine Echtzeitanwendung erforderlich ist, relativiert. Der Aufwand zur Bereitstellung des CI wird entsprechend den Anforderungen nicht als Teil des Prognosekonzeptes betrachtet. Einen Beitrag zur Kosten-Nutzen-Analyse liefert das Optimierungspotential, welches mit dem MMDL durch Vorgabe der Leistungsparameter für die Prognose bestimmt wird. Eine vollständige Kosten-Nutzen-Analyse ist aufgrund der Komplexität jedoch nicht Teil dieser Arbeit.

Die Prognoseleistungsfähigkeit lässt sich durch folgende Elemente beschreiben [118]:

- K1.1 Genauigkeit der Prognose
- K1.2 Präzision der Prognose
- K1.3 Robustheit der Prognose
- K1.4 Trajektorie der Prognoseergebnisse

Der Großteil bekannter Bewertungskonzepte basiert auf der Analyse der Genauigkeit und Präzision von Prognosealgorithmen bei der Bestimmung von RUL^* , während zur Bewertung der Robustheit und Trajektorie bisher keine einheitlichen Kriterien definiert worden sind, bzw. eine eindeutige Definition dieser Elemente noch aussteht [118]. Weiterführende Arbeiten konzentrierten sich auch im Wesentlichen auf die Bewertung der Elemente K1.1 und K1.2. Die Auswertung der Leistungsfähigkeit des GP-UKF-Ansatzes wird deswegen ebenfalls hauptsächlich anhand ausgewählter Kriterien aus den Bereichen K1.1 und K1.2 vorgenommen. In [119] wird weiterhin das Konvergenzverhalten der Prognoseergebnisse als wichtiger Bestandteil der Bewertung definiert. Während in [119] jedoch nur die Konvergenz während einer individuellen Prognoseaufgabe betrachtet wurde, wird im Rahmen dieser Arbeit ein Konzept vorgeschlagen, um auch das Lernverhalten mit zunehmender Qualität und Quantität der Trainingsdaten zu bewerten:

Bewertungskategorie	Aussage
Genauigkeit der Prognose	Beschreibt die Fähigkeit der Prognose RUL^* möglichst exakt an RUL anzunähern
Präzision der Prognose	Beschreibt die Fähigkeit der Prognose die Verteilung $p(EoP CI)$ möglichst exakt an die empirische Verteilung $p(EoL)$ anzunähern sowie die Unsicherheit bei der Bestimmung von RUL^* zu optimieren
Konvergenzverhalten für Einzeltrajektorien	Beschreibt die Adaptionsfähigkeit der Prognose an einen beobachteten Teilverlauf
Konvergenzverhalten für globalen Trainingsdatensatz	Beschreibt das Lernverhalten der Prognose bei einer Erweiterung der Trainingsdatensätze

Tabelle 11: Gewählte Kategorien zur Bewertung der Prognosefähigkeiten

Die theoretischen Grundlagen für die einzelnen Bewertungskriterien sowie die Vorgehensweise zur Implementierung werden im Folgenden näher beschrieben.

6.1.1. Herleitung des Prognosehorizontes

Als Grundlage für die hierarchische Herleitung der verwendeten Kriterien dient die Darstellung der Prognoseergebnisse im α - λ -Diagramm. Mittels dieser Darstellung kann schrittweise entschieden werden, ob das untersuchte Prognosekonzept vorgegebenen Anforderungen entspricht. Nach [119] besteht der erste Schritt der Bewertung in der Herleitung des Prognosehorizonts (PH), durch den der Nutzungsbereich in Betriebsstunden, Lastzyklen, Schaltvorgängen etc. definiert ist, über den hinweg eine zuverlässige Prognose möglich ist. Hierfür wird ein konstantes Toleranzband um den Optimalwert des Degradierungsverlaufes genutzt, um den Eintrittspunkt in diesen Bereich als Stabilitätskriterium der Prognose zu definieren:




Abbildung 58: α - λ -Diagramm zur Herleitung des Prognosehorizontes

Der Parameter PH wird durch den normierten Zeitpunkt λ_{PH} definiert, ab dem der prognostizierte Verlauf stabil innerhalb der vorgegebenen Grenzen verbleibt:

$$\text{Kriterium S1:} \quad PH_i = 1 - \lambda_{PHi} \mid \left\{ i' = \arg \min_i \left\{ \left| RUL^*_{i,j} - RUL_{i,j} \right| \leq \alpha_0 \right\} \right\} \quad (8.1)$$

mit:

$$\lambda_{PH} = \frac{t_{0PH}}{EoL}$$

$$\alpha_0 = \text{Zulässiger Toleranzbereich für Prognoseergebnisse}$$

Wenn der PH die grundlegenden Stabilitätsanforderungen erfüllt, die notwendig sind um eine prä-diktive Maßnahme zu realisieren (Vorlaufzeit zur Ersatzteilbestellung, Missionsplanung, Ressourcenmanagement etc.), können die Eigenschaften der Elemente K1.1-K1.4 bewertet werden.

6.1.2. Bewertung der Genauigkeit

Kriterien zur Bewertung der Genauigkeit sollten im Wesentlichen geeignet sein, um den Prognosefehler ε_P und dessen Verlauf in Abhängigkeit von verschiedenen Startpunkten der Prognose t_0 zu berücksichtigen. Hierzu bietet sich zunächst der MAPE mit exponentieller Gewichtung der Startpunkte nach (7.13) und (7.18) an:

$$\text{Kriterium G1:} \quad MAPE = \sum_{i=1}^{N_T} \left(\frac{\sum_{j=1}^{N_S} \left(\frac{\varepsilon_{P,i,j}}{EoL_i} \cdot w(\lambda_{i,j}) \right)}{\sum_{j=1}^{N_S} w(\lambda_{i,j})} \right) \cdot \frac{1}{N_T} \cdot 100 \quad (8.2)$$

Für prädiktive Maßnahmen spielen besonders der Verlust an operationeller Zeit durch den vorzeitigen Austausch, bzw. die Sicherheit im Betrieb durch den zu späten Austausch einer degradierenden Komponente eine wesentliche Rolle. Zur Darstellung dieser Eigenschaft können die Parameter „False Negatives“ (FN) und „False Positives“ (FP) verwendet werden:




Abbildung 59: α - λ -Diagramm zur Herleitung von FNs und FPs

Ein FN, bzw. FP Szenario besteht für Prognoseanteile, die außerhalb der durch $RUL \cdot \alpha_{FN,FP}$ definierten Bereiche verlaufen. Wird eine prädiktive Maßnahme zu diesen Zeitpunkten $t_{0FN,FP}$ eingeplant, führt die Abweichung zwischen RUL^* und RUL zu einem Fehlerfall im Betrieb, bzw. erhöhten Verlust an operativer Zeit. Wenn die Abweichung innerhalb der durch $\alpha_{FN,FP}$ definierten Bereiche liegt, wird durch das Risikomanagement, das durch die Verteilung $p(EoP|CI)$ ermöglicht wird, die Planung der Maßnahme zu den angegebenen Zeitpunkten $t_{0TN,TP}$ zu einem vernachlässigbaren Verlust an operationeller Zeit, bzw. einer Vermeidung des Fehlers im Betrieb führen. Für die Klassifikation dieser Prognoseanteile wird der Begriff „True Negatives“ (TN) und „True Positives“ (TP) definiert. Die Vertrauensbereiche für FN und FP können unterschiedliche Ausdehnungen haben.

Üblicherweise ist die zulässige relative Abweichung für TN geringer als für TP, da eine reduzierte Verfügbarkeit des Systems weniger kritisch gesehen wird als ein Fehlerfall im Betrieb. Die Parameter FN und FP sind somit wie folgt definiert:

$$\text{Kriterium G2: } FN = \sum_{i=1}^{N_T} \sum_{j=1}^{N_S} \delta_{FNi,j} \begin{cases} 1 & \text{wenn } (RUL^*_{i,j} - RUL_{i,j}) \geq RUL_{i,j} \cdot \alpha_{FN} \\ 0 & \text{sonst} \end{cases} \quad (8.3)$$

$$\text{Kriterium G3: } FP = \sum_{i=1}^{N_T} \sum_{j=1}^{N_S} \delta_{FPi,j} \begin{cases} 1 & \text{wenn } (RUL^*_{i,j} - RUL_{i,j}) \leq -RUL_{i,j} \cdot \alpha_{FP} \\ 0 & \text{sonst} \end{cases} \quad (8.4)$$

mit:

α_{FN} = Zulässiger Toleranzbereich für FNs (0-1)

α_{FP} = Zulässiger Toleranzbereich für FPs (0-1)

Um die relative Genauigkeit der Prognose zu jedem Zeitpunkt bewerten zu können („*Prognostic Accuracy*“ - PA), ist anstelle der konstanten Bandbreite wie für den PH ein konstanter relativer Fehlerbereich zu untersuchen:




Abbildung 60: α - λ -Diagramm zur Herleitung von PA

Der Parameter PA wird hierbei durch den normierten Zeitpunkt λ_{PA} definiert, ab dem der prognostizierte Verlauf stabil innerhalb der relativen Fehlerbereiche verbleibt:

$$\text{Kriterium G4: } PA_i = 1 - \lambda_{PAi} \mid \left\{ i' = \arg \min_i \left\{ \left| RUL^*_{i,j} - RUL_{i,j} \right| \leq RUL_{i,j} \cdot \alpha_{PA} \right\} \right\} \quad (8.5)$$

mit:

$$\lambda_{PA} = \frac{t_{0PA}}{EoL}$$

α_{PA} = Zulässiger Toleranzbereich für relativen Prognosefehler (0-1)

Somit ergeben sich zusätzlich zum PH die Kriterien G1-G4, die im weiteren Verlauf der Arbeit zur Bewertung der Prognosegenauigkeit genutzt werden.

6.1.3. Bewertung der Präzision

Für die Bewertung der Präzision der Prognose spielen folgende Eigenschaften eine wesentliche Rolle [98], [118]:

- (a) Stellt die Verteilung $p(EoP|CI)$ zu jedem Zeitpunkt sicher, dass der wahre Wert EoL innerhalb der prognostizierten Vertrauensbereiche liegt, bzw. durch die Wahl eines geeigneten Wertes der PoF der Fehler im Betrieb vermieden werden kann?
- (b) Wie groß ist die zu erwartende Varianz der Verteilung $p(EoP|CI)$ in Abhängigkeit von dem Startpunkt der Prognose t_0 ?
- (c) Konvergiert die Varianz mit Verschiebung des Startpunktes t_0 zu EoL hinreichend schnell gegen einen zulässigen Wert?
- (d) Wie groß ist die zu erwartende Streuung des Prognosefehlers ε_p ?

Aussage (a) lässt sich über die „Probability of Error“ - PE anhand der Ausfallwahrscheinlichkeit PoF_{EoL} zum Zeitschritt $t_k = EoL$ überprüfen. Wenn die Bedingung nach (8.6) erfüllt ist, liegt der wahre Wert nicht innerhalb der Vertrauensbereiche des prognostizierten Verlaufes und ermöglicht somit keine prädiktive Maßnahme:

$$\text{Kriterium P1: } PE = \sum_{i=1}^{N_T} \sum_{j=1}^{N_S} \delta_{PoFi,j} \begin{cases} 1 & \text{wenn } PoF_{EoLi,j} = 0\% \text{ oder } PoF_{EoLi,j} = 100\% \\ 0 & \text{sonst} \end{cases} \quad (8.6)$$

Zur Analyse der Aussagen (b) und (c) wird die Bewertung der Prognoseunsicherheit als Funktion des Startpunktes der Prognose („Prognostic Precision“ - PP) analog zur PA aus dem α - λ -Diagramm hergeleitet:

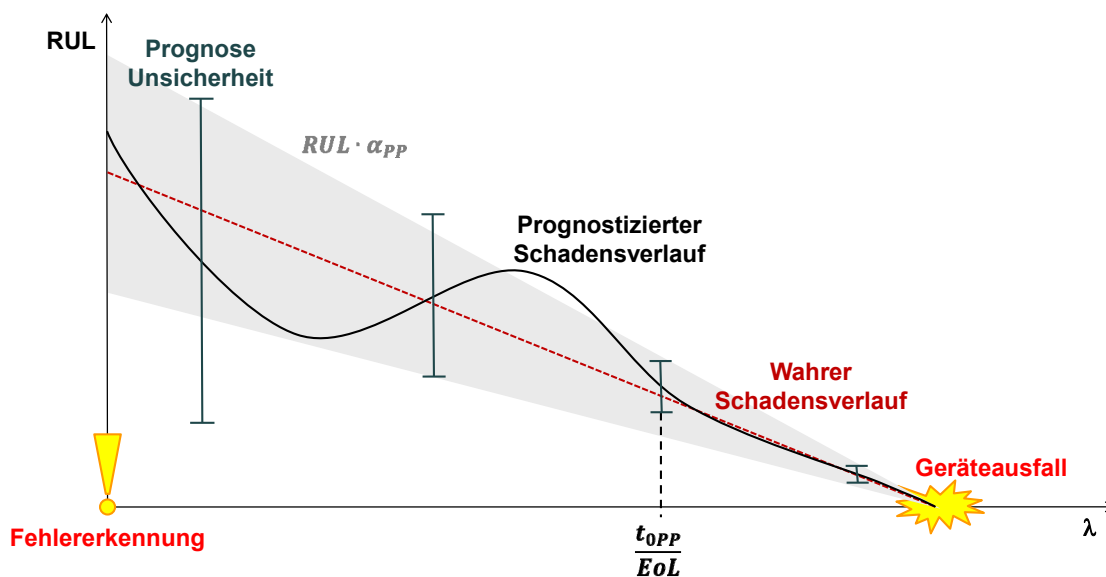


Abbildung 61: α - λ -Diagramm zur Herleitung von PP

Für die PP ist der normierte Zeitpunkt λ_{pp} von Interesse, ab dem jeweils eine ausgewählte obere und untere Perzentile der Verteilung $p(EoP|CI)$ stabil innerhalb eines vorgegebenen relativen Fehlerbereiches verlaufen:

$$\text{Kriterium P2: } PP_i = 1 - \lambda_{PP_i} \mid \lambda' = \arg \min_i \left\{ RUL^*_{i,j} \pm p_R \cdot \sigma^2_{RUL^*_{i,j}} - RUL_{i,j} \right\} \leq RUL_{i,j} \cdot \alpha_{PP} \} \quad (8.7)$$

mit:

$$\lambda_{PP} = \frac{t_{0PP}}{EoL}$$

α_{PP} = Zulässiger Toleranzbereich für relative Prognoseunsicherheit (0-1)

Die Streuung des Prognosefehlers ε_P entsprechend Forderung (d) wird mit der Standardabweichung SSD nach (7.14), (7.18) und (7.19) bestimmt:

$$\text{Kriterium P3: } SSD = \sqrt{\frac{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} ((\varepsilon_{P,i,j} - \bar{\varepsilon}_P)^2 \cdot w(\lambda_{i,j}))}{\sum_{i=1}^{N_T} \sum_{j=1}^{N_S} w(\lambda_{i,j}) - \bar{w}(\lambda)}} \quad (8.8)$$

Die in [119] angegebene Unterscheidung zwischen normalverteilten Größen und Ergebnissen mit asymmetrischer Verteilungsform wird hierbei vernachlässigt.

6.1.4. Bewertung des Konvergenzverhaltens

Für die Bewertung der lokalen Konvergenz („Local Convergency“ - LC) für eine einzelne Trajektorie ist das in [119] beschriebene Verfahren zur Bestimmung des Flächenschwerpunktes $S_{x,y}$ für die relative Genauigkeit der Prognose r_P verwendet worden:

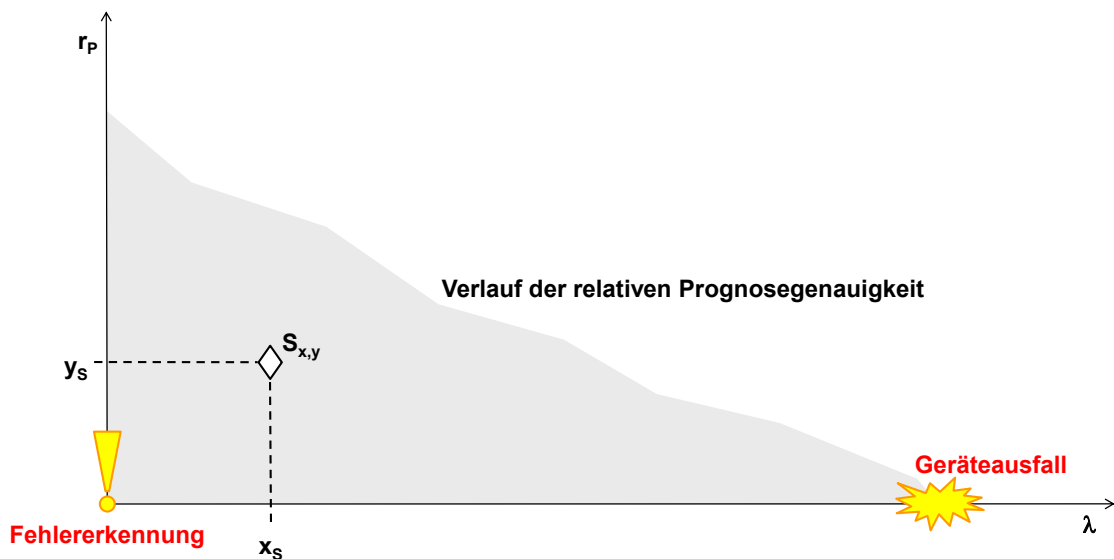


Abbildung 62: Herleitung des lokalen Konvergenzkriteriums für die relative Prognosegenauigkeit

Das Bewertungskriterium nach (8.9) basiert auf der euklidischen Distanz zwischen $S_{x,y}$ und dem Flächenursprung x_0, y_0 des Verlaufes der relativen Prognosegenauigkeit:

$$\text{Kriterium K1:} \quad LC_i = \sqrt{\left(\frac{x_{Si}}{EoL_i} - \frac{x_{0i}}{EoL_i}\right)^2 + (y_{Si} - y_{0i})^2} \quad (8.9)$$

$$\text{wobei:} \quad x_{Si} = \frac{0,5 \cdot \sum_{j=1}^{N_S-1} (t_{0i,j+1}^2 - t_{0i,j}^2) \cdot r_{Pi,j}}{\sum_{j=1}^{N_S-1} (t_{0i,j+1} - t_{0i,j}) \cdot r_{Pi,j}} \quad (8.10)$$

$$y_{Si} = \frac{0,5 \cdot \sum_{j=1}^{N_S-1} (t_{0i,j+1} - t_{0i,j}) \cdot r_{Pi,j}^2}{\sum_{j=1}^{N_S-1} (t_{0i,j+1} - t_{0i,j}) \cdot r_{Pi,j}} \quad (8.11)$$

$$r_{Pi,j} = \left| \frac{RUL_{i,j} - RUL_{i,j}^*}{RUL_{i,j}} \right| \quad (8.12)$$

Durch die Normierung der Koordinaten $x_{S,0}$ in (8.9) mit EoL ist die Lage des Schwerpunktes analog zu den Kriterien für Genauigkeit und Präzision unabhängig von der Länge des betrachteten Szenarios. Um auch die Lernfähigkeit der Prognose zu beurteilen, kann das globale Konvergenzverhalten („Global Convergency“ - GC) des Prognosealgorithmus anhand der Steigerung der Leistungsfähigkeit in Abhängigkeit von der Anzahl der genutzten Trainingsdaten $n_k = 1:N_D$ bewertet werden:

$$\text{Kriterium K2:} \quad GC_v = \frac{\sum_{k=1}^{N_D} w(n_k) \cdot v}{\sum_{k=1}^{N_D} w(n_k)} \quad (8.13)$$

$$\text{wobei:} \quad w(n_k) = \exp\left(\left(n_k - \arg \max_n \{n_{1:N_D}\}\right) \cdot p_n\right) \quad (8.14)$$

mit:

v = Bewertungskriterium mit $V = [S1, G1, G2, G3, G4, P1, P2, P3, K1]$

Mit (8.14) kann analog zu (7.18) über den Skalierungsparameter p_n die exponentielle Gewichtung der Anzahl an verwendeten Datensätzen vorgegeben werden.

6.1.5. Zusammenfassung der Bewertungskriterien

Somit ergeben sich ausgewählte Bewertungskriterien aus den Bereichen Stabilität, Genauigkeit, Präzision und Konvergenz. Die abschließende Bewertung des globalen Konvergenzverhaltens kann für alle lokalen Kriterien durch die exponentielle Gewichtung der Anzahl von verwendeten Trainingsdatensätzen realisiert werden:

Bewertungskriterium	Einheit	Aussage
S1 - Prognosehorizont (PH)	λ	Vorhersagenszeitraum mit zuverlässiger Prognose
G1 - Mean Absolute Percentage Error (MAPE)	%	Mittlerer prozentualer Fehler
G2 - False Negatives (FN)	%	Anzahl verspäteter Maßnahmen
G3 - False Positives (FP)	%	Anzahl verfrühter Maßnahmen
G4 - Prognostic Accuracy (PA)	λ	Absolute Genauigkeit
P1 - Probability of Error (PE)	%	Bewertung von $p(EoP CI)$
P2 - Prognostic Precision (PP)	λ	Absolute Präzision
P3 - Sample Standard Deviation (SSD)	%	Streuung des Prognosefehlers ε_p
K1 - Local Convergency (LC)	λ	Lokale Konvergenz der relativen Prognosegenauigkeit
K2 - Global Convergency (GC)	-	Globale Konvergenz aller Bewertungskriterien

Tabelle 12: Zusammenstellung der verwendeten Bewertungskriterien

Um eine Vergleichbarkeit zwischen unterschiedlichen Prognoseansätzen zu ermöglichen kann mittels einer Relevanzgewichtung der einzelnen Kriterien („*Weighted Performance Average*“ - WPA) eine zusammenfassende Aussage vorgenommen werden:

$$\text{Kriterium W1:} \quad WPA = \frac{\sum_{i=1}^{N_V} w(v_i) \cdot v_i}{\sum_{i=1}^{N_V} w(v_i)} \quad (8.15)$$

mit:

$w(v_i)$ = Gewichtung Kriterium i entsprechend Relevanz für die globale Bewertung

6.2. Vorgehensweise zur Bewertung der Prognosefähigkeit

Die Prognoseergebnisse der Einzeltrajektorien und Prognosestartpunkte werden zur Herleitung der Prognosekennzahlen für jeden Verifikationsdatensatz über alle getesteten Verläufe empirisch gemittelt. Die Systemidentifikation wurde für alle Datensätze jeweils mit 100 Generationen und 100 Individuen pro Generation durchgeführt. Für die experimentellen Daten ist aufgrund der geringeren Anzahl an Datensätzen der Trainingsdatensatz eine Teilmenge des Verifikationsdatensatzes. Die verwendete Gewichtung der einzelnen Bewertungskriterien während der Systemidentifikation entsprechend (6.17) ist in Tabelle 13 gegeben. Die hohe Gewichtung für F1 stellt sicher, dass auch geringe Schätzfehler in der Bewertung der Filterauslegung und Modellauswahl entsprechend berücksichtigt werden. Dies ist notwendig, da die Qualität der Störgrößenschätzung durch die Verwendung als Datenmodul während der Prognosephase maßgeblichen Einfluss auf die Qualität der Prognoseergebnisse hat.

Während der Voruntersuchungen zur Verifikation des GP-UKF-Ansatzes hat sich herausgestellt, dass durch die Vorgabe von konservativen Kovarianzen zur Zustandsschätzung und einer nachträglichen Anpassung zur konsistenten Filterauslegung ein besseres Ergebnis erzielt werden kann, als wenn hierfür ausschließlich die Optimierung der Filtergleichungen durch die *Genetische Programmierung* verwendet wird. Bei der nachträglichen Anpassung können die Kriterien F2-F4 als Indikatoren zur konsistenten Auslegung genutzt werden. Entsprechend den Ergebnissen aus § 4.4.3 wird das Kriterium F2 hierbei als wesentliche Bewertungsgrundlage verwendet.

Durch die geringe Gewichtung von F2-F4 konzentriert sich der GP-UKF auf die Herleitung einer Modellstruktur, die eine optimierte Prognose ermöglicht, indem F1 und F5-F7, die eine direkte Aussage über die Eignung des Modells zur Prognose zulassen, optimiert werden. Des Weiteren wird über die hohe Gewichtung von F1 die Qualität der Zustandsschätzung bereits indirekt mit über den Schätzfehler berücksichtigt, da bei einer unzuverlässigen Bestimmung der Zustände auch der mittlere quadratische Fehler der Schätzung ansteigt. Das Kriterium F5 ist weniger relevant als der MAPE und die SSD, da während der Prognose die Aufgabe nicht darin besteht, den exakten Verlauf des Schadensmerkmals wiederzugeben, sondern den Ausfallzeitpunkt möglichst zuverlässig vorherzusagen. Dennoch wird F5 zur Bewertung verwendet, um sicher zu stellen, dass der prognostizierte Verlauf auch vor dem Ausfallzeitpunkt eine Ähnlichkeit mit dem Trainingsdatensatz aufweist.

Bewertungskriterium	Gewichtung
F1 - $RMSE_S$	10^3
F2 - $\phi(\varepsilon_i)$	10^{-3}
F3 - $\bar{\rho}$	10^{-3}
F4 - $\tilde{\rho}$	10^{-3}
F5 - $RMSE_P$	10^{-2}
F6 - MAPE	10
F7 - SSD	1

Tabelle 13: Gewichtung der Bewertungskriterien für die Systemidentifikation

Die Validierung der Prognosequalität als Teil der Systemidentifikation erfolgt zur Reduzierung der Rechenzeit für die Startpunkte $t_0 = [0,1;0,5;0,9] \cdot \lambda$ und durch $p_\lambda = 0$ ohne Berücksichtigung des Gewichtungsfaktors aus (7.18), wodurch jeder Startpunkt der Prognose bei der Bewertung der Systemidentifikation gleichermaßen berücksichtigt wird. Die Vertrauensbereiche der propagierten Verteilung $p(CI|u)$ und der resultierenden Verteilung $p(EoP)$ werden durch die Wahl der dreifachen Standardabweichung σ_{CI} und σ_{EoP} bestimmt.

Die Analyse der Prognoseleistungsfähigkeit wird entsprechend den in § 6.1 beschriebenen Kriterien mit folgender Parametrisierung vorgenommen:

Parameter	Parameterwert
α_0	0,1
α_{FN}	0,1
α_{FP}	0,2
α_{PA}	0,2
α_{PP}	0,9
t_0	$[0,1;0,2;\dots;0,9]\cdot\lambda$
p_λ	0

Tabelle 14: Verwendete Einstellungen für die Bewertungskriterien der Prognosefähigkeit

Für die Genauigkeitskriterien ist die genannte Unterscheidung der Relevanz zwischen FNs und FPs durch $\alpha_{FN} < \alpha_{FP}$ vorgenommen worden. Der vergleichsweise hohe Wert für α_{PP} wird benötigt, um die Ergebnisse auswerten zu können, da bei $\alpha_{PP} \leq 0,8$ nur ein Teil der Verläufe das geforderte Kriterium erfüllt und somit die Vergleichbarkeit zwischen verschiedenen Verläufen und Ansätzen nicht gegeben wäre. Die Startpunkte der Prognose wurden durch das Intervall $t_0 = [0,1;\dots;0,9]\cdot\lambda$ mit einer Schrittweite von $\Delta\lambda = 0,1$ festgelegt.

Für alle genutzten Datensätze werden zur Illustration der Ergebnisse aus der Systemidentifikation jeweils der über alle Generationen normierte Fitnessverlauf sowie die absoluten, ungewichteten und durch eine nachträgliche manuelle Anpassung der Filterkovarianzen optimierten Bewertungskriterien für die letzte Generation dargestellt. Mit dem über alle Verifikationsläufe gemittelten Prognosefehler wird das Konvergenzverhalten des Prognosekonzeptes diskutiert.

Zur Illustration der Modellanteile während der Prognose und der Vertrauensbereiche der Verteilung $p(EoP)$ sind in Anhang C für die synthetischen Daten zusätzliche Ergebnisse für zufällig ausgewählte Einzeltrajektorien und die Gesamtpopulation eines Datensatzes gegeben. Aufgrund der detaillierten Analyse des Lernverhaltens werden diese Anteile für die experimentellen Daten in § 6.4.3 ausführlicher diskutiert als für die synthetischen Daten.

Die Bereiche zur Datenklassifikation entsprechend (7.61) und (7.62) zur Unterstützung des *Multiple-Model-Ansatzes* aus § 5.3.3 sind einheitlich für alle Datensätze mit $p_0 = 0,325$ und $p_e = 0,825$ gewählt worden. Durch diese Wahl werden drei Modelle hergeleitet, von denen durch das erste und letzte Modell jeweils ein besonders statisches, bzw. dynamisches Verhalten abgebildet werden und der durchschnittliche Gradient $\partial CI/\partial t$ mit $\sim 50\%$ Auftretenswahrscheinlichkeit durch das zweite Modell simuliert wird. Die Festlegung der Randbedingungen zur Modellauswahl hat nicht zu vernachlässigende Auswirkungen auf die Qualität der Prognoseergebnisse, soll hier jedoch aufgrund der Komplexität nicht weiter untersucht werden. Es sollte lediglich berücksichtigt werden, dass die dargestellten Ergebnisse nicht zwangsläufig die optimale Lösung darstellen, da entweder durch eine

andere Wahl der Datenklassifikation für die hybride Systemidentifikation oder die Anzahl der Iterationen der *Genetischen Programmierung* und Individuen pro Generation das erreichte Ergebnis beeinflusst werden kann. Die gezeigten Ergebnisse sollen lediglich dazu dienen, die vielfältigen Einsatzgebiete des GP-UKF-Ansatzes aufzuzeigen. Aus dem Vergleich mit dem UKF-GAP-Ansatz soll zusätzlich eine Unterscheidung in konzeptspezifische und testspezifische Limitationen vorgenommen und somit eine Entscheidungsgrundlage für Verbesserungspotentiale erarbeitet werden. Zur Bewertung der Prognosefähigkeit und aufgrund der rechenintensiven Vorgehensweise während der Trainingsphase wurde für die synthetischen Daten auf die Beurteilung der Lernfähigkeit (Kriterium K2) verzichtet. Die Verbesserung der Prognose wird aufgrund der geringeren Anzahl an vorhandenen Datensätzen ausschließlich für die experimentellen Daten analysiert. Der Wert von Kriterium K2 ist ohne Vergleichsgrundlage nicht aussagekräftig, weswegen der Einfluss der Trainingsdaten auf die Qualität der Prognose anhand der jeweiligen Einzelergebnisse diskutiert wird.

6.3. Simulierte Daten

Bei der Modellierung für die synthetischen Trainingsdaten werden neben dem eigentlichen Merkmalsverlauf auch beliebige äußere Lastbedingungen, ein stochastisches Ausfallverhalten sowie die Verteilung $p(EoL)$ mit vorgegebenem Erwartungswert $E[EoL]$ und entsprechenden Unsicherheiten berücksichtigt. Da der simulierte Verlauf die Ausprägung eines Schadensmerkmals abbilden soll, ist ein monoton steigendes Verhalten anzustreben²⁵. Hierfür ist ein linearer Modellierungsansatz verfolgt worden, der ausgehend von einem Startwert CI_0 den Verlauf des CI abbildet und den Gradienten $\partial CI / \partial t$ als Funktion der Betriebsbedingungen F_i simuliert:

$$CI_k = CI_{k-1} + \left(\frac{\partial CI}{\partial t} \right)_{k-1} \cdot \sum_i F_{i,k-1} + v_{k-1} \quad (8.16)$$

mit:

$F_{i,k}$ = Skalierte externe Last i zum Zeitschritt k mit $F_{i,k} = F_{exti,k} \cdot \mu_k \cdot \delta_k$

μ_k = Exponentialverteilte Zufallszahl zum Zeitschritt k mit $\mu_k \sim \text{Exp}(\log(CI_k / CI_0))$

δ_k = Sprungfunktion für normalverteilte Zufallszahl zum Zeitschritt k : $\delta_k = \begin{cases} 1 & n_k \leq p_n \\ 0 & n_k > p_n \end{cases}$

n_k = Gleichverteilte Zufallszahl zum Zeitschritt k mit $n_k \sim U(0,1)$

p_n = Grenzwert für Krafteinwirkungen auf den Degradierungsverlauf

v_k = Normalverteilte Zufallszahl mit $v_k \sim N(\mu_v, \sigma_v^2)$

²⁵ Während ein Sensorwert in Abhängigkeit von den Betriebsbedingungen ein nahezu beliebiges Verhalten aufweisen kann, besitzt der Verlauf einer Schadensgröße für technische Systeme immer ein monoton steigendes Verhalten, da zur Wiederherstellung eine entsprechende Reparaturmaßnahme erforderlich wird.

Durch die Nutzung der skalierten externen Kraft $F_{i,k}$ anstelle des direkten Wertes $F_{exti,k}$ kann über μ_k der steigende Einfluss auf das Degradierungsverhalten als Funktion der Schadensausprägung berücksichtigt werden. Um die Trägheit der Systemantwort auf sich ändernde Betriebsbedingungen abzubilden, werden die Verläufe der skalierten externen Lasten F_i als tiefpassgefilterte, gleichverteilte Größen mit $F_{exti} \sim U(F_{mini}, F_{maxi})$ simuliert:




Abbildung 63: Beispielhafter Verlauf für simulierte externe und skalierte externe Last mit $F_{min} = 0$ und $F_{max} = 15$: (a) Skalierung mit $\mu = 1$, (b) Skalierung mit $\mu = 1,5$

In [120] wird ein ähnlicher Ansatz wie mit (8.16) verfolgt, den Gradienten $\partial CI / \partial t$ für ein lineares Schadensmodell als zweiparametrisch weibullverteilte Zufallszahl zu modellieren²⁶:

$$\left(\frac{\partial CI}{\partial t} \right)_k = \eta_k \cdot (-\log(u))^{1/\beta} \quad (8.17)$$

mit:

u = Normalverteilte Zufallszahl mit $u \sim N(\mu_u, \sigma_u^2)$

η_k = Skalierungsparameter der Weibullverteilung zum Zeitschritt k

Während in [120] jedoch aus dem linearen Modell ein Ausdruck für die Verteilung $p(EoL)$ hergeleitet wird, ist die Zielsetzung dieser Arbeit die Entwicklung eines Simulationsmodells für den Schadensverlauf unter Vorgabe der Verteilung $p(CI_{max})$ und der statistischen Momente der Verteilung $p(EoL)$. Für die Nutzung zur Prognose sind alle bekannten Eingangsgrößen, der Verlauf des zu prognostizierenden CI und zur Bestimmung der PoF die Verteilung $p(CI_{max})$ von Interesse. Ein Komponentenausfall zum Zeitschritt k wird simuliert, wenn die Bedingung $CI_{k+1} \geq CI_{max}$ erfüllt ist. Die Verteilung $p(CI_{max})$ wird aus den Werten CI_{maxi} abgeleitet, die diese Bedingung erfüllen:

$$CI_{maxi} = CI_{i,k} \mid \{CI_{i,k} < CI_{pmi} \wedge CI_{i,k+1} \geq CI_{pmi}\} \quad (8.18)$$

mit:

CI_{pmi} = Maximale Schadensgröße Degradierungsverlauf i mit $CI_{pmi} \sim N(E[CI_{max}], \sigma_{CI_{max}}^2)$

²⁶Allgemein eignet sich die Weibullverteilung im Besonderen zur Modellierung von Materialvariabilität oder stochastischem Ausfallverhalten von elektromechanischen Komponenten oder Strukturbauteilen.

Diese Vorgehensweise zur Bestimmung von CI_{max} ist erforderlich, um den Verlauf und damit auch die Prognostizierbarkeit des CI nicht zu beeinflussen.

Der Effekt auf die simulierten Verläufe besteht in einer erhöhten Streuung des maximalen Degradierungswertes, da bei einem entsprechend großen Gradienten des CI während des Zeitschrittes $k+1$ der Wert von CI_k , der dann das jeweilige Maximum des Degradierungsverlaufes bildet, noch auf einem niedrigen Niveau verlaufen kann. Daraus resultiert bei entsprechender Parametrisierung die relativ große Streuung der Verteilung $p(CI_{max})$.

Dieser Effekt erhöht die Anforderungen während der Trainings- und Validierungsphase, wodurch für die Verläufe mit großer Streuung von $p(CI_{max})$ auch mit einem entsprechenden Einfluss auf die Ergebnisse der Prognose zu rechnen ist.

Um die in § 3.4.1 als relevant definierten Kategorien von Schadensverläufen zu berücksichtigen, sind ein linearer und exponentieller Ansatz angenommen und ausgehend von (8.16) jeweils ein entsprechender Ausdruck für η_k aufgestellt worden. Die Herleitung des Skalierungsparameters η_k unter Vorgabe von $E[EoL]$ berücksichtigt keine äußeren Lasten, weswegen die Dauer bis zum Fehlerfall mit zunehmendem Einfluss von F_{ext} entsprechend abnimmt. Dieses Verhalten hat jedoch keinen Einfluss auf die Ergebnisse der Verifikation des Prognosekonzeptes, da der GP-UKF-Ansatz den Ausdruck für $E[EoL]$ aus den empirischen Daten herleitet, ohne die Auslegungskriterien für das Design der betrachteten Komponenten, bzw. Verläufe zu berücksichtigen.

Die Klassifikation der genutzten Datensätze in entsprechende Anteile zur Systemidentifikation, Validierung und Verifikation wurde zufällig vorgenommen. Wie für datenbasierte Verfahren üblich, hat die Qualität der verwendeten Datensätze einen maßgeblichen Einfluss auf die Qualität der Lösung, weswegen die Aufbereitung von Datensätzen als wichtiger Bestandteil der Lösungsfindung betrachtet werden muss. An dieser Stelle wird jedoch angenommen, dass aufgrund der Menge an verfügbaren Daten eine zufällige Auswahl von Trainings-, Validierungs- und Verifikationsdaten eine hinreichend gute Basis für die Verifikation der Prognosefähigkeiten ermöglicht.

6.3.1. Lineare Schadensmodelle

Ausgehend von der allgemeingültigen Darstellungsform des Erwartungswertes für weibullverteilte Zufallszahlen mit Skalierungsparameter η und Formparameter β ist eine Reihenentwicklung für den Erwartungswert der maximalen Schadensgröße $E[CI_{max}]$ mit $CI_{max} \sim N(E[CI_{max}], \sigma_{CI_{max}}^2)$ vorgenommen worden:

$$E[CI_{max}] = CI_0 + \frac{E[EoL]}{\Delta t} \cdot \eta_L \cdot \Gamma\left(\frac{\beta+1}{\beta}\right) \quad (8.19)$$

Daraus lässt sich unter Berücksichtigung eines linearen Verlaufes ein Ausdruck für den Skalierungsparameter η_k zur Nutzung von (8.17) herleiten:

$$\eta_k = \eta_L = \frac{E[CI_{\max}] - CI_0}{\frac{E[EoL]}{\Delta t} \cdot \Gamma\left(\frac{\beta+1}{\beta}\right)} \quad (8.20)$$

Für die Simulation der Schadensverläufe werden die Erwartungswerte $E[EoL]$ und $E[CI_{\max}]$ sowie der Startwert der Degradierung CI_0 als bekannt vorausgesetzt. Die Streuung des Degradierungsverhaltens wird neben den äußeren Lasten im Wesentlichen durch den Formparameter der zugrundeliegenden Weibullverteilung β beschrieben. Dieser wird während des Verlaufes als konstant angenommen²⁷.

Unter Vorgabe eines zufällig generierten Wertes CI_{\max} mit $CI_{\max} \sim N(E[CI_{\max}], \sigma_{CI_{\max}}^2)$ lassen sich somit durch Vorgabe von Startwerten und fixen Parameterwerten verschiedene Formen von linearen Degradierungsverläufen generieren.

Für die Verifikation der Prognosefähigkeiten des GP-UKF-Ansatzes sind für den linearen Anteil drei verschiedene Formen mit jeweils 100 individuellen Verläufen verwendet worden (Parameterwerte zur Modellkonfiguration s. [Anhang B](#)).

Die drei durch Parametrisierung von (8.16), (8.17) und (8.20) verwendeten Modelle unterscheiden sich durch die Ausprägung des stochastischen Anteils und des Einflusses der simulierten Betriebsbedingungen.

Das Schadensmodell L1 simuliert einen Verlauf mit hohem Einfluss der externen Last und moderatem stochastischen Anteil, während Modell L2 einen annähernd linearen Verlauf ohne Berücksichtigung von Betriebsbedingungen und einem vernachlässigbaren stochastischen Anteil abbildet und das Simulationsmodell L3 schließlich einen hohen Anteil des stochastischen Degradierungsverhaltens mit einem moderaten Anteil der Betriebsbedingungen vereinbart.

Die gewählten Parameterwerte ermöglichen eine Abbildung von unterschiedlichen Eigenschaften des Degradierungsverhaltens unter Verwendung einer einheitlichen Modellstruktur. Wie aus [Abbildung 64](#) ersichtlich, werden die Modelle L1 und L3 größere Herausforderungen an eine zuverlässige Prognose stellen als L2, da die Streuung der Einzelverläufe wesentlich größer ist. Durch die relativ große Streuung des maximalen Degradierungswertes wird die erreichbare PoF ebenfalls eine entsprechend große Streuung aufweisen.

²⁷ Die Implementierung einer mathematisch geschlossenen Form für die Varianz σ_{EoL}^2 und die Herleitung eines entsprechenden Ausdruckes für β ist nicht ohne weiteres möglich, da eine funktionale Abhängigkeit zwischen η und β besteht. Ein möglicher Ansatz wäre eine Maximum-Likelihood-Analyse der Ausdrücke für den Erwartungswert und die Varianz, worauf hier zur Reduzierung der Komplexität jedoch verzichtet wurde.

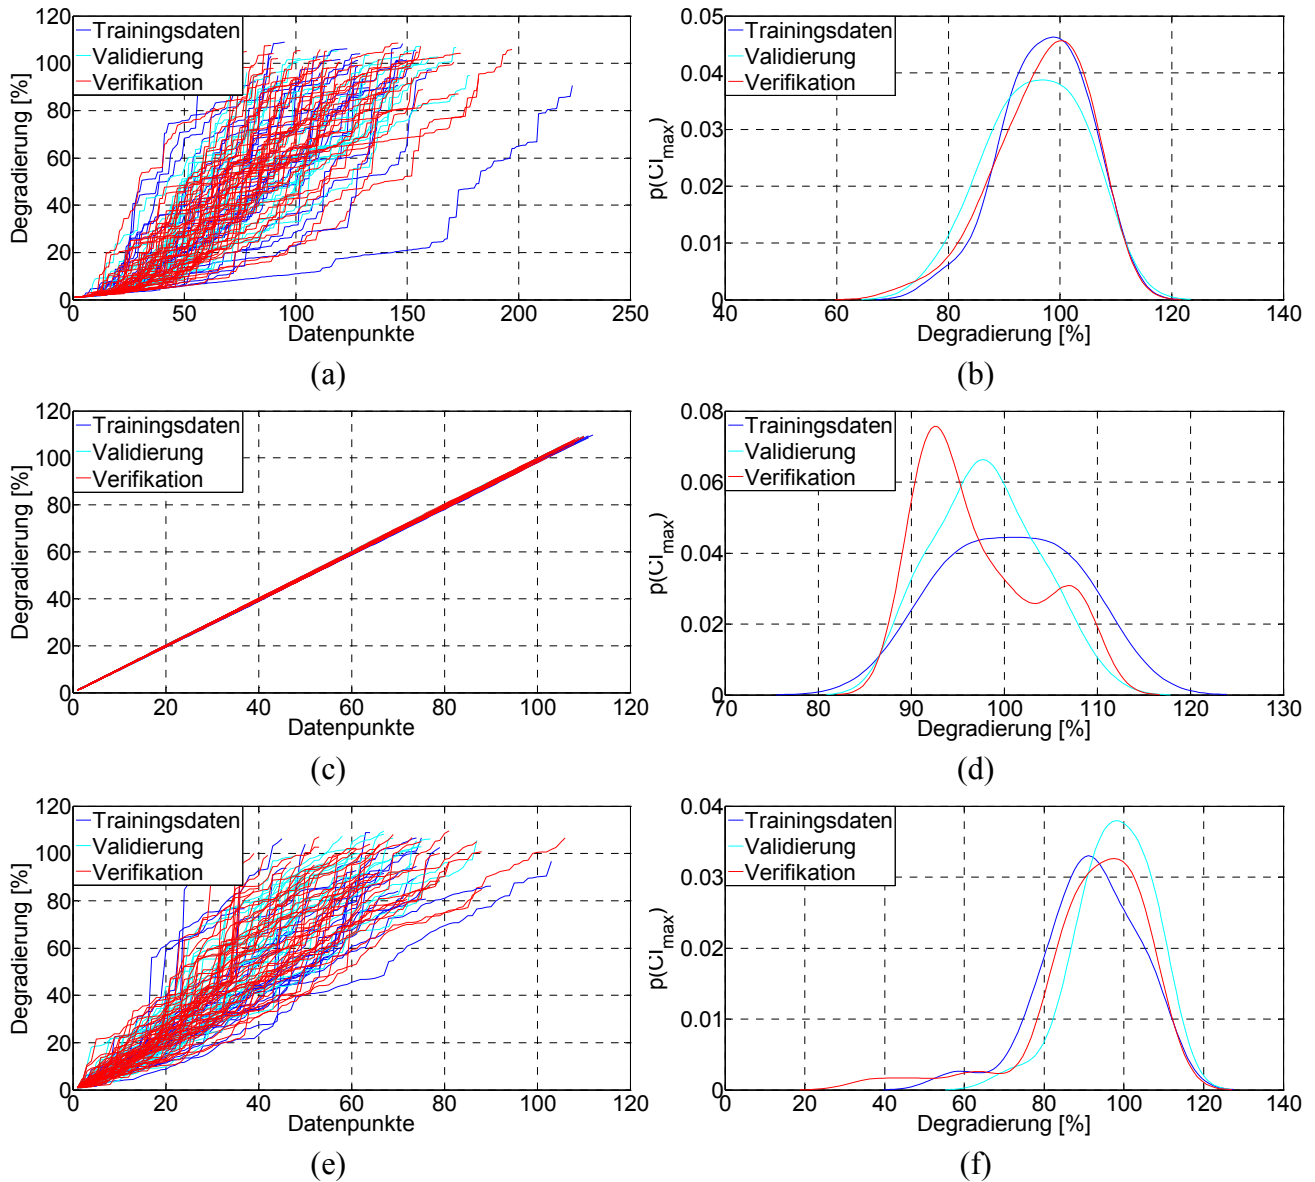


Abbildung 64: Lineare Schadensmodelle L1-L3: (a), (c), (e) Simulierte Merkmalsverläufe, (b), (d), (f) Resultierende Verteilung der maximalen Schadensgröße $p(CI_{max})$

Die Systemidentifikation zeigt für alle linearen Modelle ein asymptotisches Verhalten des Fitnessverlaufes mit einer Tendenz, die gegen ein Optimum strebt (s. [Abbildung 65](#)), womit die Konvergenz der Herleitung einer Prognosefunktion nachgewiesen wird (zur besseren Vergleichbarkeit der Ergebnisse wird der normierte Fitnessrend dargestellt). Ausgehend von dem Verlauf über die letzten 50% der genutzten Generationen kann bereits zu diesem Zeitpunkt ein stabiles Niveau der Bewertungskriterien angenommen werden, was auf ein globales oder lokales Optimum der hergeleiteten Funktion und Filterauslegung schließen lässt. Die Unterscheidung ob ein globales oder lokales Optimum erreicht wurde, lässt sich anhand eines einzelnen Ergebnisses nicht vornehmen.

Die dargestellten Bewertungskriterien entsprechen den ungewichteten Werten und basieren auf der nachträglich manuell angepassten Filterparametrisierung für Q_{ξ} und Q_x :

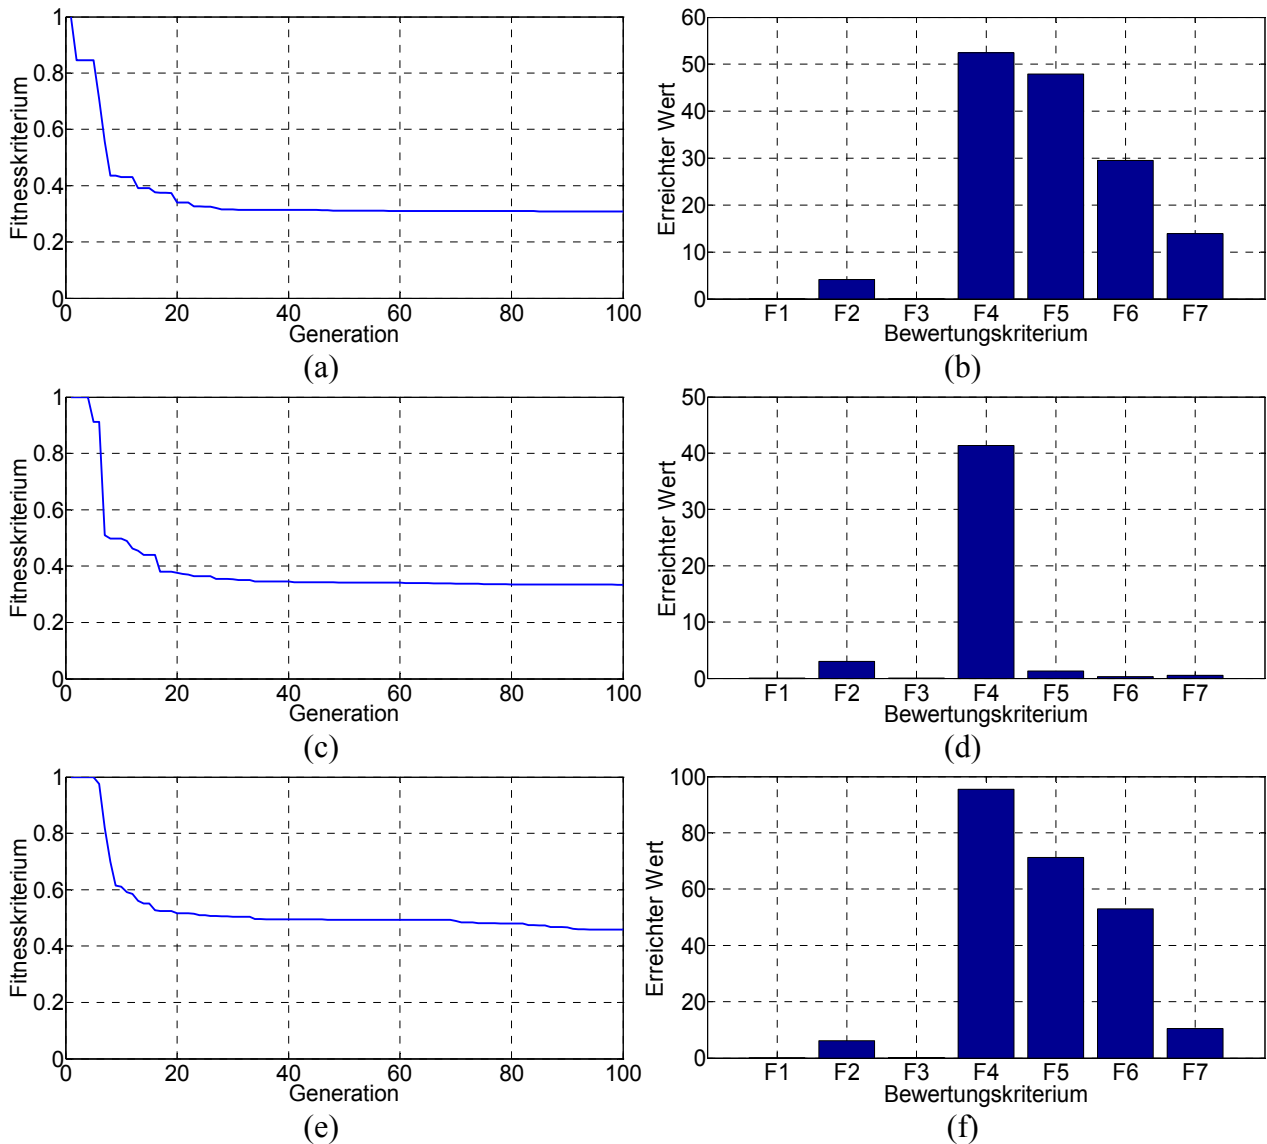


Abbildung 65: Prognosefunktion für Schadensmodelle L1-L3: (a), (c), (e), Fitnessverlauf über Systemidentifikation, (b), (d), (f), Anteile der Bewertungskriterien für letzte Generation

Aus den dargestellten Verläufen der normierten Fitnesskriterien lassen sich zwei mögliche Schlüsse ziehen:

1. Die verwendete Anzahl an Individuen ermöglicht bereits relativ früh ein optimiertes und stabiles Ergebnis, was auch bei einer Erhöhung der Anzahl an Individuen und Generationen nicht mehr weiter verbessert werden kann.
2. Die verwendete Anzahl an Individuen ist zu gering, weswegen der Ergebnisraum bereits früh eingeschränkt wird und die gefundene Lösung durch die fitnessproportionale Reproduktion nur noch wenige Unterschiede in den Individuen aufweist. Damit ist der Prozess auf eine umfassende Mutation angewiesen ist, um das lokale Optimum zu verlassen. Die Wahrscheinlichkeit für eine umfassende Mutation mit diesem Steigerungspotential ist jedoch so gering, dass die Anzahl der Individuen und Generationen nicht ausreicht um das globale Optimum weiter anzunähern.

Für eine detaillierte Analyse müssten alle Szenarien mit verschiedenen Kombinationen für die Anzahl der Individuen und Generationen getestet werden. Ein mögliches Szenario könnte aus folgenden Testfällen bestehen:

1. 1000 Generationen mit jeweils 100 Individuen.
2. 100 Generationen mit jeweils 1000 Individuen.
3. 1000 Generationen mit jeweils 1000 Individuen.

Alle Testfälle müssten hinreichend oft durchlaufen werden, um eine statistisch repräsentative Aussage zu erhalten. Es ist zu erwarten, dass Szenario 3 das beste Ergebnis liefert, jedoch kann zur Reduzierung der Anforderungen an eine Simulationsumgebung untersucht werden, wie sich die Qualität der Prognose zwischen 1 und 2 unterscheidet, welche Variante das bessere Resultat erzielt und wie viel Verbesserungspotential zusätzlich durch 3 ermöglicht wird. Zur Reduzierung der Komplexität wurde auf diese Vorgehensweise verzichtet, sie bietet jedoch eine sinnvolle Maßnahme für weiterführende Untersuchungen, um mit einem minimierten Aufwand ein optimiertes Ergebnis zu erhalten.

Eine vollständig konsistente Filterauslegung wurde für keines der Modelle erreicht, was vermutlich an dem ebenfalls in § 4.4.1 beobachteten Einflusses des Random-Walk-Ansatzes für die Störgrößenschätzung liegt. Die *Genetische Programmierung* hat jedoch auch ohne eine manuelle Filterauslegung bereits eine gute Schätzung der Schadensgröße x und Störgröße ξ ermöglicht, womit die nachträgliche manuelle Anpassung der Filterparameter keine nennenswerten Auswirkungen mehr auf die Qualität der Prognose hatte.

Hierbei bleibt jedoch zu beachten, dass die gefundene Lösung aufgrund der oben genannten Aspekte nicht als globales Optimum betrachtet werden sollte und theoretisch die Möglichkeit besteht, mit einer anderen Konfiguration der *Genetischen Programmierung* (z.B. größere Anzahl an Individuen und Generationen oder andere Parametrisierung der Wahrscheinlichkeiten für die Auswahl der genetischen Operatoren) ein globales Optimum mit konsistenter Filterauslegung und optimierter Prognosefähigkeit zu erreichen.

Der über alle Verifikationsanteile gemittelte Verlauf des Prognosefehlers ε_P (s. [Abbildung 66](#)) zeigt für alle linearen Modelle eine mit dem Startpunkt der Prognose hinsichtlich Genauigkeit und Präzision zunehmende Konvergenz der Prognosegüte. Das Modell L3 weist sowohl für den Mittelwert als auch für die Streuung des Prognosefehlers eine verhältnismäßig große Abweichung von der Ideallinie auf, weswegen dieses Szenario im Folgenden näher untersucht wird, um daraus nach Möglichkeiten Verbesserungen für den GP-UKF herleiten zu können. Die Verläufe für L1 und L2 ermöglichen bereits ab $\lambda \geq 0,1$ ein für den betrachteten Anwendungsfall optimiertes Ergebnis.

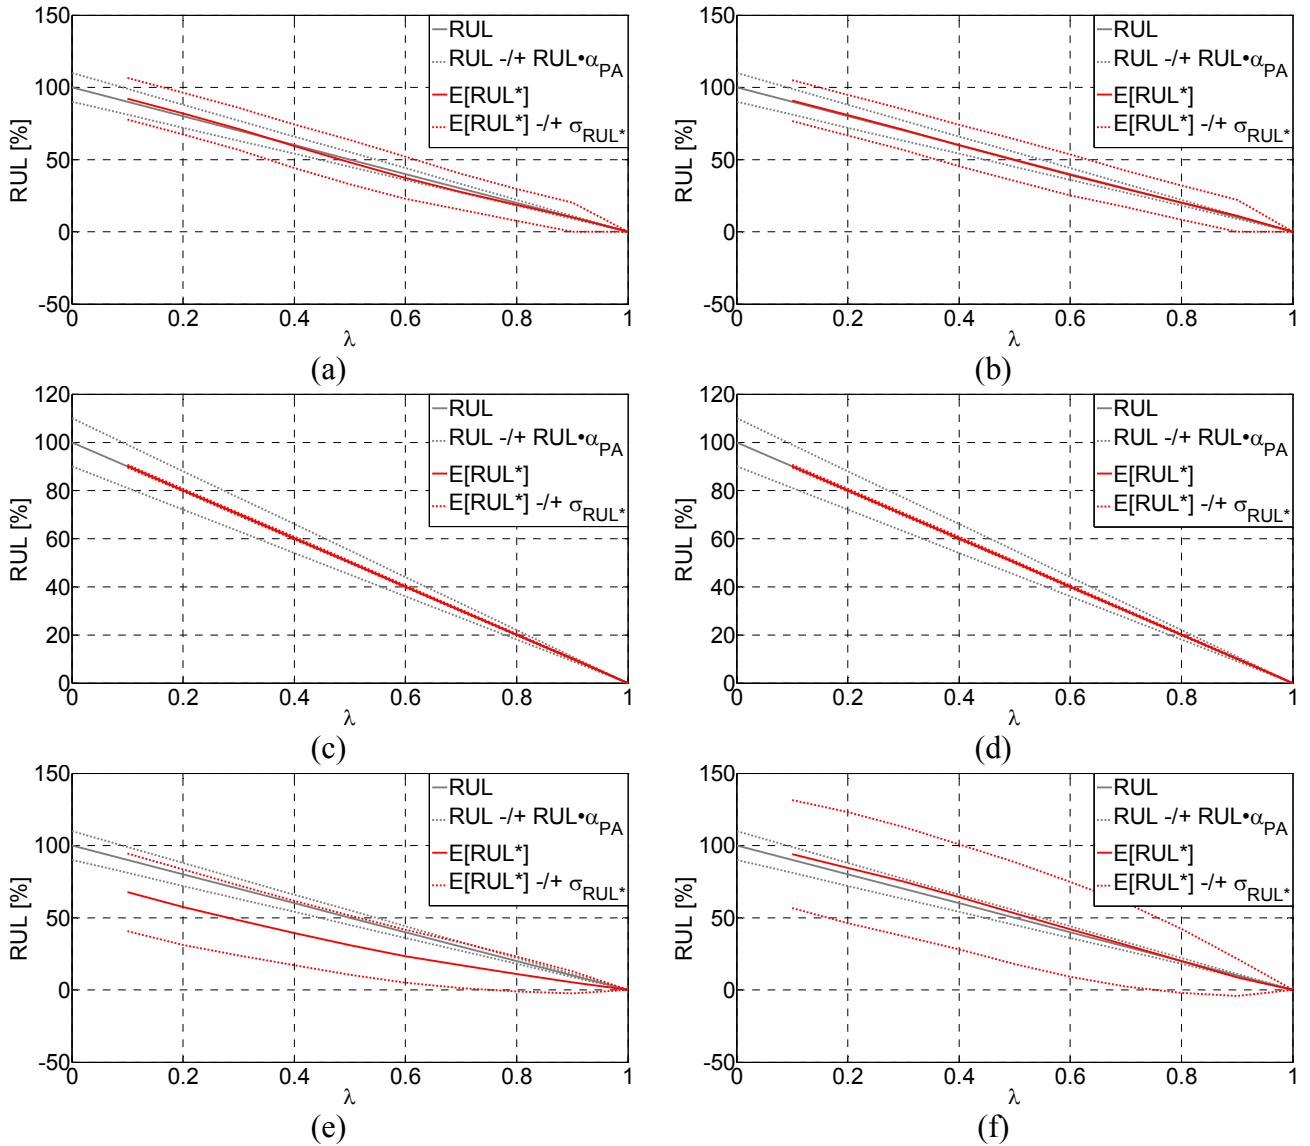


Abbildung 66: Erwartungswert und Standardabweichung des Prognosefehlers über gesamten Datensatz Schadensmodelle L1-L3: (a), (c), (e) Ohne Korrekturfaktor, (b), (d), (f) Mit Korrekturfaktor

Das beobachtete Verhalten lässt sich mit der Auslegung der Modelle begründen:

Während für das Modell L1 der erhöhte Einfluss der äußeren Lasten die Identifikation und Prädiktion eines für jeden Teilverlauf individuellen Verhaltens erleichtert, ist der Einfluss der Unsicherheiten und äußeren Lasten für Modell L2 vernachlässigbar, weswegen die Systemidentifikation für beide Szenarien schnell eine geeignete Lösung findet.

Das Modell L3 besitzt einen starken Einfluss des stochastischen Ausfallverhaltens und einen im Vergleich zu Modell L1 vernachlässigbaren Anteil der äußeren Lasten (diese Aussage lässt sich nach (7.28) und (7.63) durch das Verhältnis der Korrelationskoeffizienten nachweisen: $r_{F,L1}/r_{F,L3} = [31,4;4,3;23,3]$ für Modell $i = 1:3$), wodurch die korrekte Prädiktion eines individuellen Teilverlaufes erschwert wird. Dennoch ermöglicht die Propagierung der damit in Verbindung stehenden Unsicherheiten bei Auswahl einer geeigneten PoF für alle Modelle eine zuverlässige Planung von prädiktiven Instandhaltungsmaßnahmen.

Bei Verwendung des globalen Korrekturfaktors lässt sich für alle Datensätze ein annähernd idealer Verlauf des gemittelten Fehlers erzielen. Die verbleibende Abweichung zwischen der Ideallinie und dem korrigierten Erwartungswert der Prognoseergebnisse resultiert aus den Unterschieden zwischen dem Trainings- und Verifikationsdatensatz und der Herleitung des normierten Startpunktes für den aktuellen Teilverlauf mittels dem Mittelwert aller beobachteten Ausfallzeitpunkte aus dem Trainingsdatensatz. Dadurch entspricht der aktuell geschätzte Startpunkt nicht dem wahren Wert, da der Ausfallzeitpunkt des zu prognostizierenden Verlaufes jedoch unbekannt ist, besteht keine andere Möglichkeit diesen aus den vorliegenden Informationen zu bestimmen (s. § 5.3.4). Wenn beide Datensätze identisch wären und der wahre Wert für den normierten Startpunkt der Prognose exakt bestimmt werden könnte, würde die Prognose mit Korrekturfaktor im Mittel ein perfektes Ergebnis ermöglichen.

Für die Umsetzung als Prognosefunktion ist die Fähigkeit relevant, die PoF als Grundlage zur Vermeidung von Fehlern im Betrieb zu verwenden. Im Durchschnitt ermöglicht die PoF für alle dargestellten Verläufe durch die Wahl eines geeigneten Zeitpunktes zur prädiktiven Instandsetzung die Gewährleistung der Sicherheit im Betrieb ($PE \rightarrow 0$). Lediglich für Modell L3 wird das geforderte Verhalten für ~27% der Prognosestartpunkte nicht erfüllt. Bei Verwendung des Korrekturfaktors lässt sich diese Problematik beheben und die resultierende PE auf 0% reduzieren.

Auch wenn für die Modelle L1 und L3 eine Streuung außerhalb des 10% Fehlerbereiches, bzw. für Modell L3 ohne Korrekturfaktor eine deutliche Abweichung von der Ideallinie zu beobachten ist, liefert das Prognosekonzept dennoch für alle dargestellten Degradierungsverläufe eine Lösung, die eine robuste Prädiktion der statistischen Momente der Verteilungen $p(CI|u)$ und $p(EoP|CI)$ sowie eine Konvergenz der Prognosegüte (ausgedrückt durch Genauigkeit und Präzision der Prognose) mit Verschiebung des Prognosestartpunktes in Richtung EoL ermöglicht.

Für die Darstellung des Einflusses der äußeren Lasten auf die erreichbare Qualität der Prognose ist Modell L3 erneut mit $p_n = 1$ analysiert worden (s. § 6.3). Somit wird zwar der absolute Wert der externen Lasten nicht beeinflusst aber durch die erhöhte Wahrscheinlichkeit, dass die Last einen Einfluss auf den Verlauf, hat auch entsprechend die Sensitivität des hergeleiteten Modells gegenüber den Betriebsbedingungen gesteigert. Wie aus Abbildung 67 ersichtlich, lässt sich durch diesen Mehrgehalt an Informationen über den individuellen Verlauf auch bei ansonsten gleicher Vorgehensweise ein deutlich besseres Ergebnis erzielen.

Wie für die anderen Teilergebnisse gilt jedoch auch hier, dass der vollständige Beweis dieser Annahme nur durch die Erweiterung der Lösungsmöglichkeiten (Anzahl Generationen und Individuen) und Generierung einer statistisch repräsentativen Anzahl an Testläufen möglich ist.




Abbildung 67: Ergebnis der Prognose für Modell L3 unter Berücksichtigung einer höheren Korrelation zwischen den Betriebsbedingungen und dem Degradierungsverlauf über gesamten Datensatz ohne Korrekturfaktor: (a) Erwartungswert und Standardabweichung des Prognosefehlers, (b) Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose

Die erhöhte Sensitivität der Prognose gegenüber den individuellen Verläufen der externen Lasten lässt sich auch der Darstellung der Einzeltrajektorien entnehmen:




Abbildung 68: Individuelle Prognoseverläufe: (a) Modell L3 in Originalkonfiguration, (b) Modell L3 mit höherer Korrelation zwischen Betriebsbedingungen und Degradierungsverlauf

Der Verlauf der Einzeltrajektorien ist für das modifizierte Modell stärker vom Startpunkt der Prognose abhängig. Während für die Originalkonfiguration teilweise ein über weite Strecken konstanter Fehler in der Prognose zu beobachten ist, variiert die Abweichung zur Ideallinie für das modifizierte Modell häufiger und konvergiert schneller gegen ein Optimum. Dieses Verhalten lässt sich damit erklären, dass für eine geringe Korrelation zwischen dem Degradierungsverhalten und einem für den jeweiligen Degradierungspfad spezifischen Lastprofil, die über alle Verläufe gemittelte Datenbasis als Hauptgrundlage zur Prognose dient und somit die Eignung für die Einzeltrajektorien weniger variiert.

Durch diesen Vergleich lässt sich nachweisen, dass der GP-UKF-Ansatz während der Modellfindung nicht nur den mittleren Prognosefehler minimiert, sondern auch die Sensitivität des CI gegenüber den genutzten Eingangsgrößen mit in die Systemidentifikation einfließen lässt. Dieses Verhalten wird bei einer Systemidentifikation zwar implizit erwartet, lässt sich mit dem betrachteten Beispiel jedoch auch anschaulich nachweisen.

Zur weiteren Veranschaulichung der Lernfähigkeiten durch die modellbasierte Systemidentifikation ist nachfolgend in Abbildung 69 für Modell L1 der Verlauf der Prognosegüte ohne Korrekturfaktor der besten Individuen der ersten im Vergleich zur letzten Generation der *Genetischen Programmierung* dargestellt:

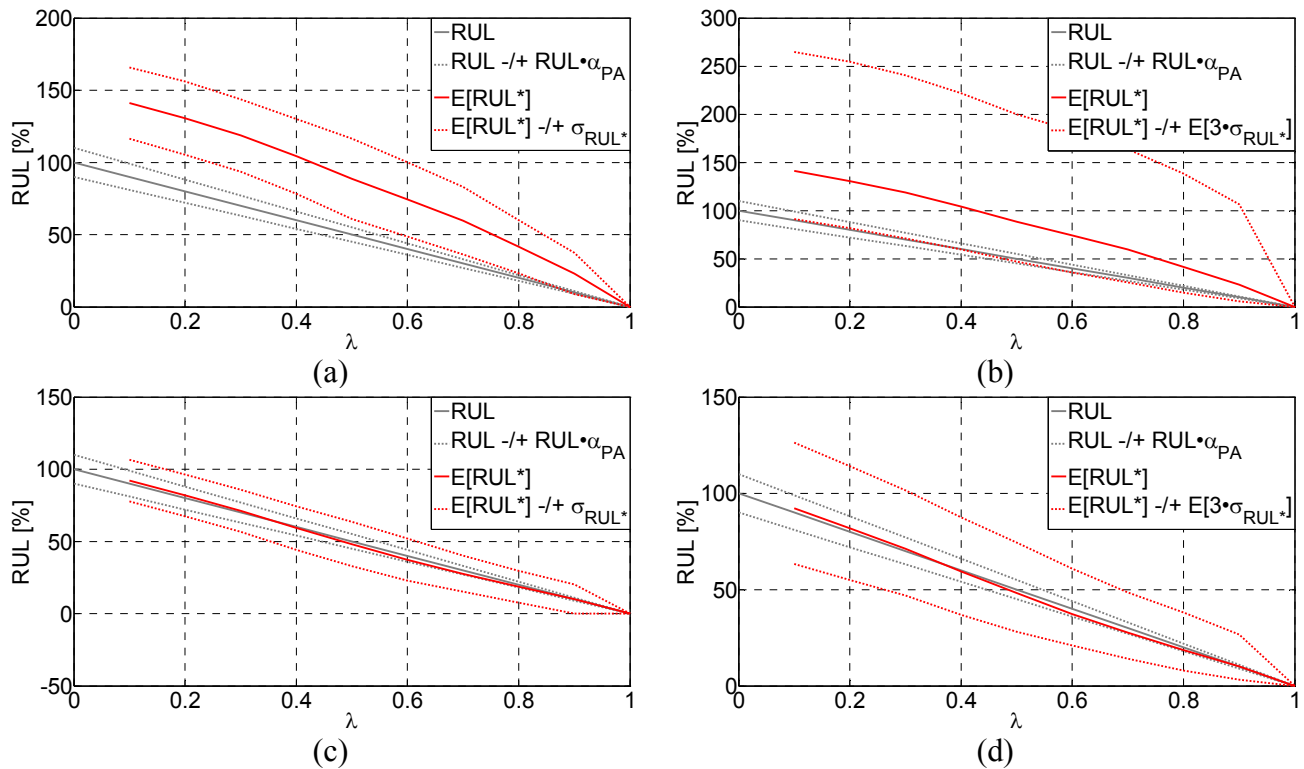


Abbildung 69: Verlauf der Prognosegüte für Modell L1 ohne Korrekturfaktor: (a) Erwartungswert und Standardabweichung des Prognosefehlers für erste Generation, (b) Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose für erste Generation, (c) Erwartungswert und Standardabweichung des Prognosefehlers für letzte Generation, (d) Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose für letzte Generation

Deutlich ist die Optimierung durch die *Genetische Programmierung* erkennbar. Während nach der ersten Generation zwar eine robuste, jedoch keineswegs brauchbare Prognosefähigkeit identifiziert wurde, war es über die angegebene Anzahl an Iterationen möglich, die Modellgleichungen und damit auch die Datenmodule zu optimieren. Ein ähnliches Verhalten lässt sich auch für die anderen Szenarien beobachten.

Damit ist neben der Konvergenz der verwendeten Fitnesskriterien auch der damit verbundene Einfluss auf die Qualität der Prognoseergebnisse nachgewiesen. Einzige Bedingung für die Konvergenz der *Genetischen Programmierung* ist, dass durch die Initialgeneration mindestens ein Individuum bereitgestellt wird, das für alle Testläufe eine Prognosefähigkeit ohne Divergenz der verwendeten Fitnesskriterien ermöglicht. Ausgehend von dieser initialen Modellstruktur konvergiert die *Genetische Programmierung* durch die fitnessproportionale Reproduktion bei hinreichender Anzahl an Generationen und Individuen gegen ein Optimum.

Aus den dargestellten Verläufen ohne Berücksichtigung des Korrekturfaktors lassen sich schließlich die Kennzahlen zur Bewertung der Prognoseleistungsfähigkeit herleiten:

Bewertungskriterium	L1	L2	L3
S1 – Prognosehorizont [λ]	0,57	0,1	0,83
G1 – Mean Absolute Percentage Error [%]	28,5	0,4	50,7
G2 – False Negatives [%]	7,2	0	14,8
G3 – False Positives [%]	3,9	0	1,6
G4 – Prognostic Accuracy [λ]	0,95	0,1	0,95
P1 – Probability of Error [%]	1,8	0	27,6
P2 – Prognostic Precision [λ]	0,85	0,1	0,75
P3 – Sample Standard Deviation [%]	5,9	0,2	6,1
K1 – Local Convergency [λ]	0,61	0,57	0,57

Tabelle 15: Bewertung der Prognoseleistungsfähigkeit des GP-UKF für Schadensmodelle L1-L3

6.3.2. Exponentielle Schadensmodelle

Der Ansatz für den exponentiellen Verlauf des CI verwendet im Gegensatz zum linearen Verlauf für die Reihenentwicklung über eine Rekursion eine Abhängigkeit von dem aktuellen Zustand des Systems:

$$E[CI_{\max}] = CI_0 \cdot \left(1 + \eta_E \cdot \Gamma\left(\frac{\beta+1}{\beta}\right) \right)^{\frac{E[EoL]}{\Delta t}} \quad (8.21)$$

Analog zu (8.19) lässt sich für die Modellierung von exponentiellen Merkmalsverläufen aus (8.21) ein Ausdruck für den Skalierungsparameter η_k herleiten:

$$\eta_k = \eta_E \cdot CI_{k-1} = \left[\frac{\frac{E[EoL]}{\Delta t} \sqrt{\frac{E[CI_{\max}]}{CI_0}} - 1 \right] \cdot \frac{1}{\Gamma\left(\frac{\beta+1}{\beta}\right)} \cdot CI_{k-1} \quad (8.22)$$

Der exponentielle Charakter wird zusätzlich durch die Abhängigkeit von CI_{k-1} realisiert. Die Vorgehensweise zur Simulationskonfiguration und Parametrisierung der exponentiellen Modelle E1-E3 entspricht den Überlegungen für lineare Modelle.

So bildet Modell E1 ebenfalls ein Szenario ab, in dem der Einfluss der externen Last überwiegt, woraus analog zu L1 die verhältnismäßig große Differenz zwischen dem Mittelwert des Ausfallzeitpunktes und dem vorgegebenen $E[EoL]$ resultiert, während auch für den exponentiellen Anteil bei Vernachlässigung der externen Lasten und des stochastischen Verhaltens durch Modell E2 ein annähernd idealisierter Verlauf des CI erreicht wird. Der kombinierte Einfluss von externen Lasten und stochastischem Verhalten wird wiederum durch das Modell E3 abgebildet:

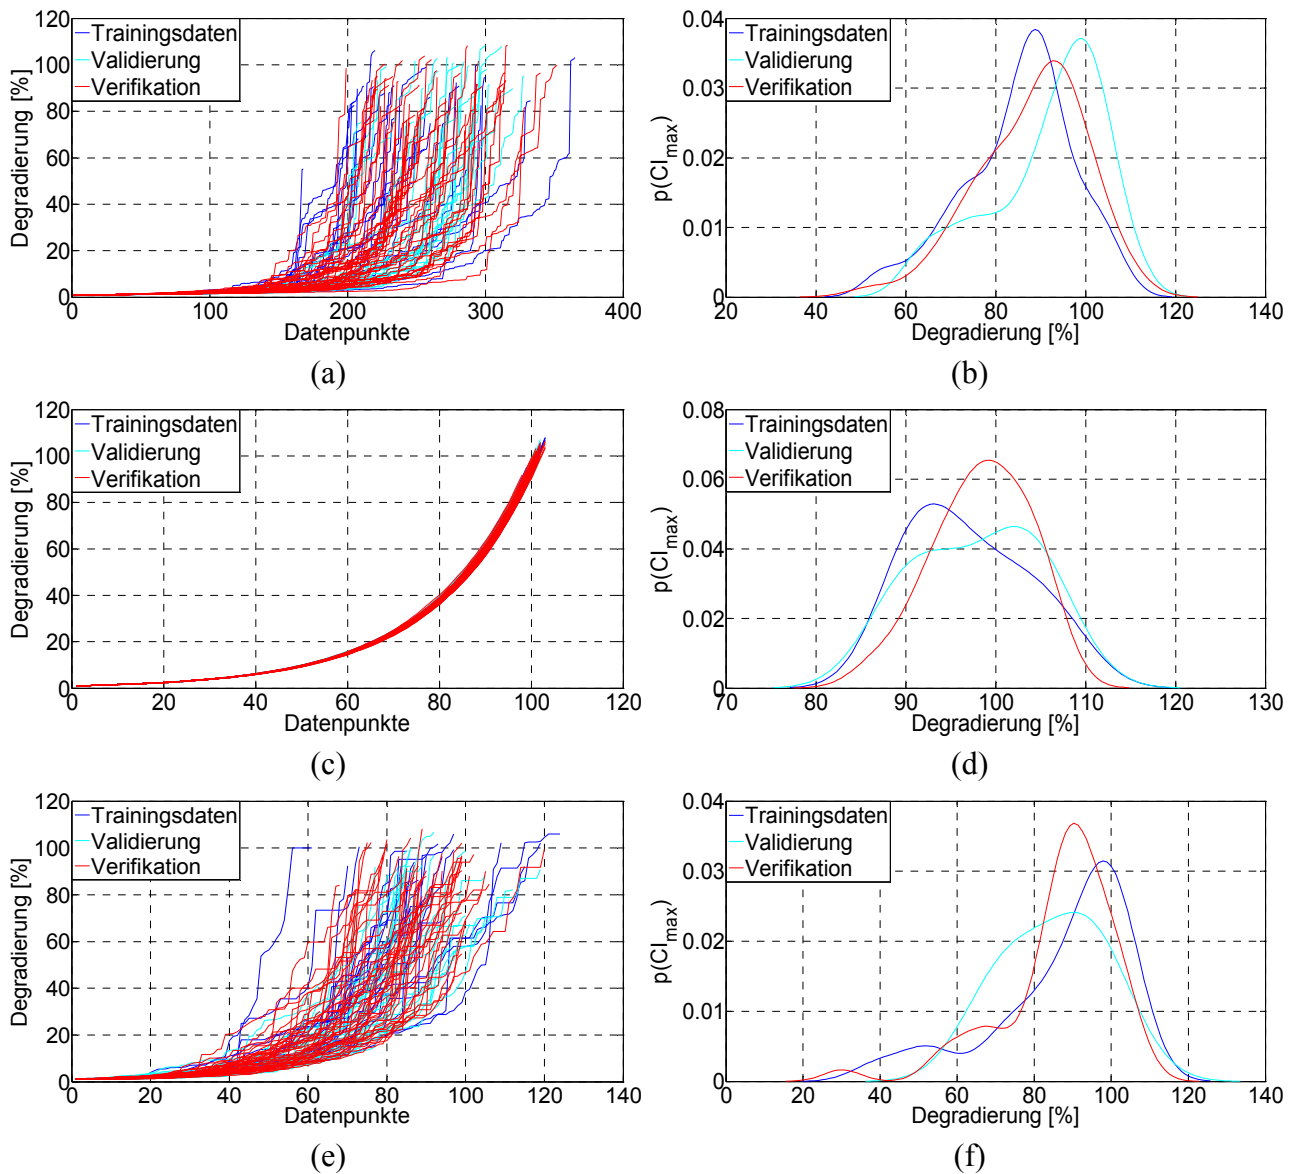


Abbildung 70: Exponentielle Schadensmodelle E1-E3: (a), (c), (e) Simulierte Merkmalsverläufe, (b), (d), (f) Resultierende Verteilung der maximalen Schadensgröße $p(CI_{max})$

Die verwendeten Parametereinstellungen sind identisch zu der Konfiguration für die linearen Modelle L1-L3 (s. [Anhang B](#)). Der unterschiedliche Charakter des Verlaufes wird durch die Implementierungsform der weibullverteilten Zufallszahlen erreicht. Analog zu den linearen Verläufen wird die Prognoseaufgabe für die Modelle E1 und E3 komplexer sein als für E2.

Durch die Vielfältigkeit der unterschiedlichen synthetischen Degradierungsverläufe lässt sich einfach zeigen, dass die verwendeten Modellstrukturen durch eine einfache Parametrisierung neben dem generellen Verhalten als lineares oder exponentielles Schadensmodell auch eine frei wählbare Sensitivität des Degradierungsverlaufes gegenüber einer beliebigen Anzahl an Betriebsbedingungen und des stochastischen Anteils ermöglichen. Somit bieten die genutzten Schadensmodelle eine vielfältig einsetzbare Grundlage zur modellbasierten Verifikation von Prognosefähigkeiten.

Auch für die exponentiellen Modelle lässt sich aus den Verläufen der normierten Fitness (s. Abbildung 71) eine Konvergenz der Systemidentifikation gegen ein globales oder lokales Optimum ableiten.

Unabhängig von dem resultierenden Fitnesswert, der aus den gewichteten Einzelkriterien besteht, wird analog zu den linearen Verläufen erwartungsgemäß das beste Ergebnis für Modell E2 erzielt. Die für die linearen Modelle diskutierte Vorgehensweise zur optimierten Parametrisierung der *Genetischen Programmierung* lässt sich auch anhand der hier gezeigten Fitnessverläufe bestätigen. Im Vergleich weisen die exponentiellen Modelle eine größere Variabilität im erreichten Optimierungspotential auf, was sich jedoch ohne die in § 6.3.1 beschriebene Vorgehensweise zur Generierung einer entsprechenden Datenbasis und der statistischen Auswertung der Ergebnisse nicht fundiert analysieren lässt.

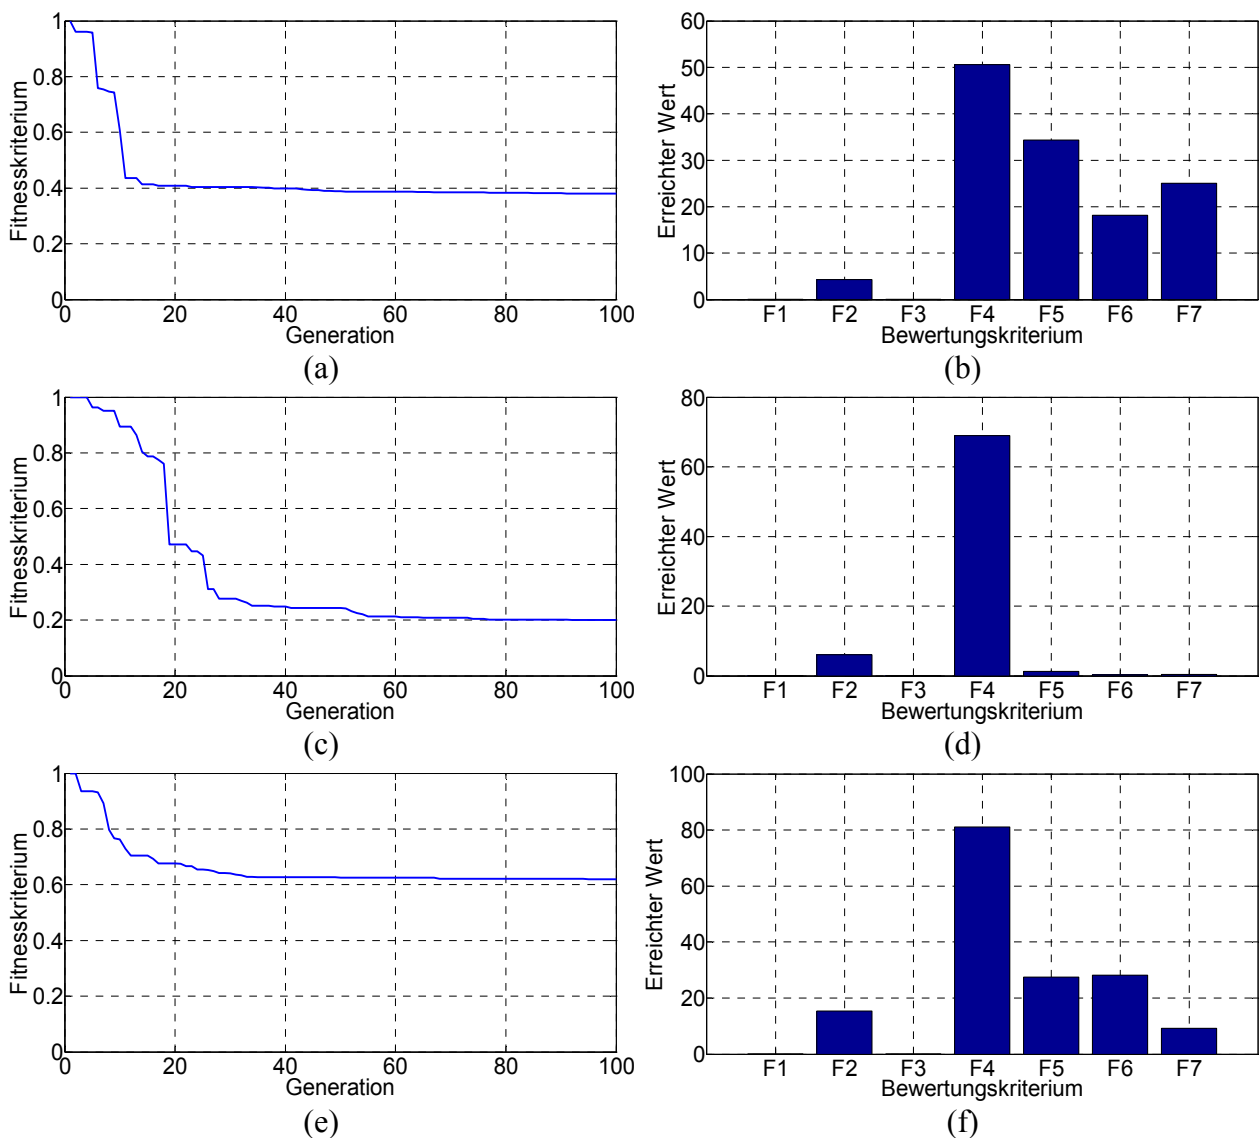


Abbildung 71: Prognosefunktion für Schadensmodelle E1-E3: (a), (c), (e) Fitnessverlauf über Systemidentifikation, (b), (d), (f) Anteile der Bewertungskriterien für letzte Generation

Die in [Abbildung 72](#) dargestellten Verläufe des gemittelten Prognosefehlers zeigen keine besonderen Auffälligkeiten. Analog zu den linearen Verläufen lässt sich auch hier durch die Verwendung des globalen Korrekturfaktors eine verbesserte Prognose erzielen. Für Modell E3 wird ebenfalls nicht dieselbe Prognosegüte erreicht wie für E1, was auch auf die reduzierte Aussagekraft der externen Lasten zurück zu führen ist. Für $\lambda \geq 0,7$ kann für die Modelle E1 & E3 eine leichte Abnahme der Prognosegüte beobachtet werden. Dieses Verhalten scheint spezifisch für die exponentiellen Verläufe zu sein und konnte bei den linearen Modellen nicht beobachtet werden.

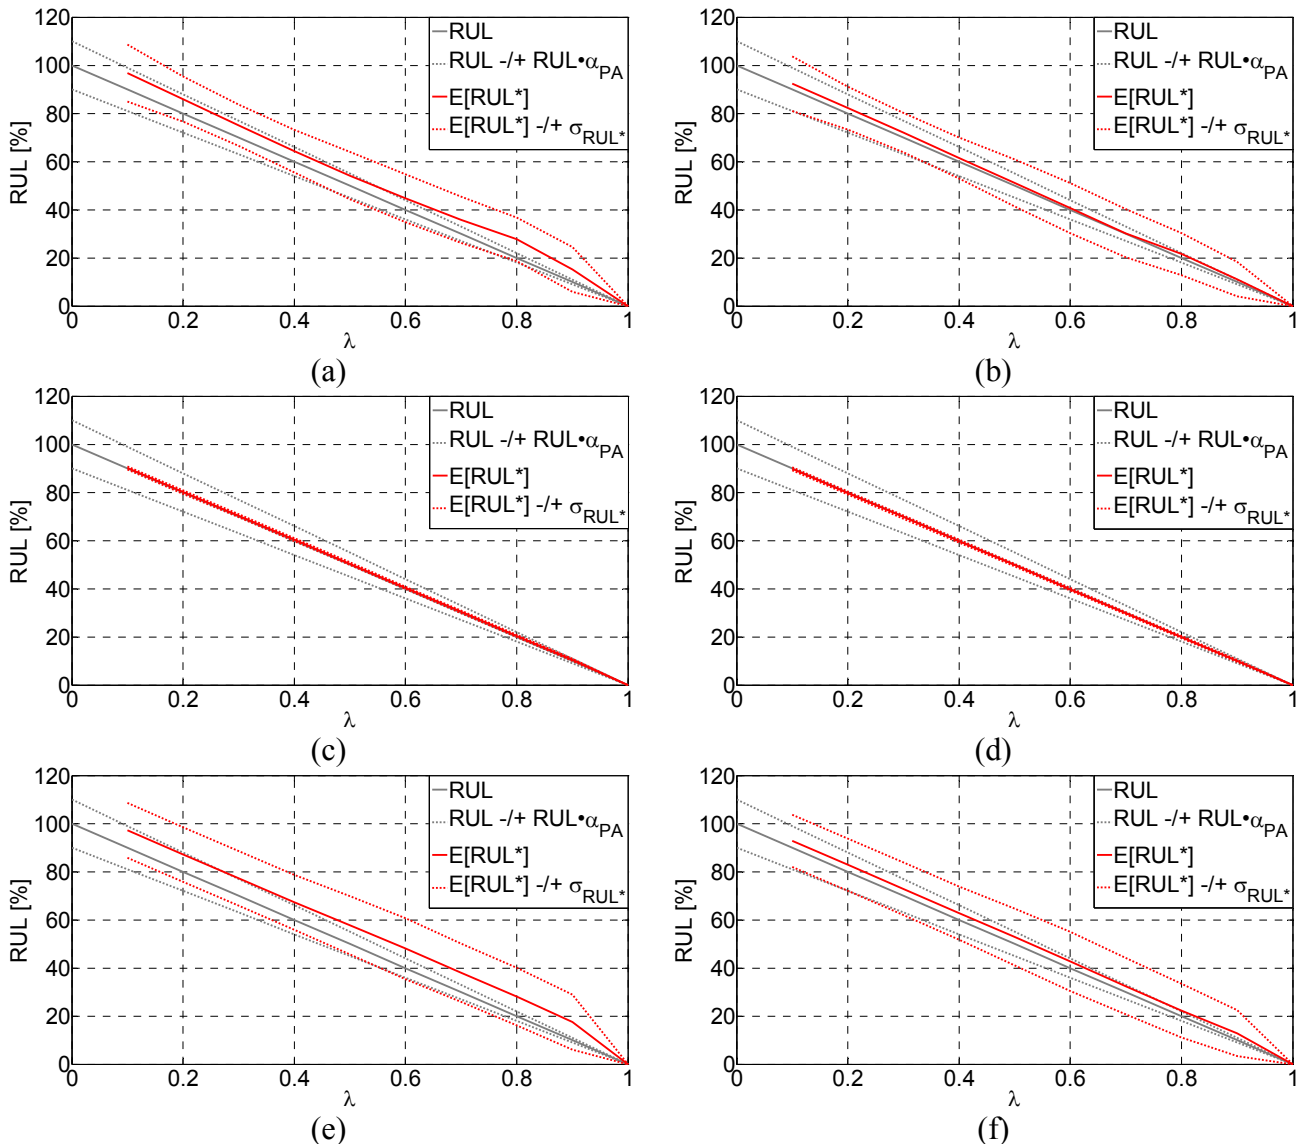


Abbildung 72: Erwartungswert und Standardabweichung des Prognosefehlers über gesamten Datensatz Schadensmodelle E1-E3: (a), (c), (e) Ohne Korrekturfaktor, (b), (d), (f) Mit Korrekturfaktor

Der wesentliche Unterschied zwischen den linearen und exponentiellen Modellen besteht im Verhalten des Gradienten der Degradierung über den simulierten Verlauf:

Die Modelle L1-L3 weisen aufgrund ihrer linearen Auslegung über den gesamten Degradierungsverlauf im Mittel einen weitestgehend konstanten Gradienten auf. Bei den exponentiellen Modellen ist hingegen besonders gegen Ende des Verlaufes ein teilweise sprunghafter Anstieg des CI zu be-

obachten, der zu Diskontinuitäten in einzelnen Verläufen und damit einer erhöhten Komplexität für die Prognosefunktion führt. Dieses Verhalten resultiert nach (8.22) aus der Abhängigkeit des berechneten Gradienten von dem aktuellen Wert der Degradierung.

Die beobachteten Abweichungen von der Ideallinie des Prognosefehlers für $\lambda \geq 0,7$ werden auf diesem Hintergrund im Folgenden näher untersucht:

Für Modell E1 wird die Abweichung zwischen der Ideallinie und $E[RUL^*]$ für $\lambda \geq 0,7$ durch eine geringe Anzahl an Einzelverläufen verursacht, die aufgrund der genannten Diskontinuitäten durch die Systemidentifikation nicht vollständig abgebildet werden konnten. Würden entweder alle oder eine statistisch signifikante Anzahl an Verläufen vergleichbare Niveaus der Diskontinuitäten aufweisen, würde dieses Merkmal vermutlich in der Modellbildung berücksichtigt werden können. Für frühe Startpunkte der Prognose fällt der relative Fehler aufgrund des größeren RUL geringer aus, woraus die Zunahme für spätere Startpunkte resultiert. Die Anzahl der abweichenden Verläufe befindet sich im einstelligen Prozentbereich und sollte somit nicht maßgeblich für eine Aussage über die Qualität der Prognose verwendet werden.

Ohne Berücksichtigung dieser Teilverläufe ergibt sich eine annähernd startpunktunabhängige Qualität der Prognose:




Abbildung 73: Ergebnis über gesamten Datensatz für Schadensmodell E1 ohne Korrekturfaktor unter Vernachlässigung starker Diskontinuitäten: (a) Erwartungswert und Standardabweichung des Prognosefehlers, (b) Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose

Ähnliches gilt für den Prognoseverlauf von Modell E3, wobei ein Anteil von $\sim 15\%$ der Trainingsdaten gegen Ende der Verläufe eine deutliche Diskontinuität im Verlauf, bzw. einen frühzeitigen Ausfall ($EoL \leq 0,5 \cdot E[EoL]$, s. [Abbildung 70 \(f\)](#)) aufweisen, die ähnlich wie bei Modell E1 durch die hergeleiteten Schadensmodelle nicht vollständig abgebildet werden können. Da der Fehler in der Prognose somit für einzelne Verläufe und Prognosestartpunkte groß ausfällt, wird das Ergebnis entsprechend beeinflusst.

Bei Vernachlässigung der Verläufe mit starker Diskontinuität und vorzeitigem Ausfallzeitpunkt ergibt sich ein über den gesamten Wertebereich stabiles Ergebnis:




Abbildung 74: Ergebnis über gesamten Datensatz für Schadensmodell E3 ohne Korrekturfaktor unter Vernachlässigung starker Diskontinuitäten und Abweichungen im Ausfallverhalten: (a) Erwartungswert und Standardabweichung des Prognosefehlers, (b) Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose

Analog zur Vorgehensweise für die linearen Modelle lassen sich aus den gemittelten Ergebnissen der Prognose ohne Berücksichtigung des Korrekturfaktors die Kennzahlen zur Bewertung der Prognoseleistungsfähigkeit für die exponentiellen Degradierungsverläufe herleiten:

Bewertungskriterium	E1	E2	E3
S1 – Prognosehorizont [λ]	0,51	0,1	0,57
G1 – Mean Absolute Percentage Error [%]	24,8	1,4	32,3
G2 – False Negatives [%]	2,1	0	2,5
G3 – False Positives [%]	5,3	0	7,1
G4 – Prognostic Accuracy [λ]	0,81	0,1	0,88
P1 – Probability of Error [%]	1,8	0	0
P2 – Prognostic Precision [λ]	0,83	0,1	1
P3 – Sample Standard Deviation [%]	10,7	0,3	2,2
K1 – Local Convergency [λ]	0,62	0,62	0,64

Tabelle 16: Bewertung der Prognoseleistungsfähigkeit des GP-UKF für Schadensmodelle E1-E3

6.4. Experimentelle Daten

Die simulierten Daten dienen dazu, mit einer möglichst geringen Anzahl an Testläufen ein möglichst breites Feld an unterschiedlichen Degradierungsverläufen abzudecken und zur Analyse des GP-UKF-Ansatzes zu verwenden. Für reale Anwendungen müssen neben den eigentlichen Schadensverläufen auch Einflüsse der Messdatenerfassung und Limitationen bei der Beobachtbarkeit der Schadensgröße berücksichtigt werden. Zur Darstellung dieser Einflüsse sind für den Nachweis der Prognoseleistungsfähigkeit unter realen Bedingungen Versuchsreihen mit einem luftfahrttauglichen Lüfter durchgeführt worden. Der verwendete Prüfling zur Messdatengewinnung ist ein Axialverdichter mit dreiphasigem Asynchronmotorantrieb (s. [Abbildung 75](#), technische Daten und Instrumentierung des verwendeten Lüfter s. [Anhang D](#)).



(a)




(b)

Abbildung 75: Verwendeter Prüfling zur Messdatengewinnung: (a) Seitenansicht, (b) Vorderansicht

Der Verschleiß der Lager zur Kraftübertragung zwischen dem rotatorischen und statischen Teil stellt eine der häufigsten mechanischen Versagensarten von Elektromotoren dar [121]. Für Lager im Allgemeinen und Elektromotoren im Speziellen existieren verschiedene Diagnoseverfahren zur Detektion und Quantifizierung von Lagerschäden, wie z.B. die Thermographie, Schmiermittelkontrolle sowie die Spektralanalyse der Statorströme oder Vibrationen der Gehäusestruktur [121].

Für die Simulation des Degradierungsverlaufes ist der Zeitpunkt ab dem der Schaden auftritt von untergeordnetem Interesse. Entsprechend der in § 5.1 gegebenen Definition ist für die Fehlerprognose lediglich der Verlauf des Schadensmerkmals ab dem Zeitpunkt der ersten Detektion bis zum Ausfall der Funktion relevant.

Aufgrund der Lage zum Propeller und der damit verbundenen höheren dynamischen Belastung, wurde das vordere Lagerelement der Rotorwelle zur Simulation des Schadensverlaufes ausgewählt:



(a)



(b)

Abbildung 76: Lagerung der Rotorwelle mit Lager für die Schadenssimulation: (a) Schematische Darstellung, (b) Demontiertes Rotorelement des Prüflings

Eine der größten Herausforderungen zur Unterstützung der Entwicklung von Prognosefähigkeiten ist die Bereitstellung von repräsentativen Datensätzen, die ein gewisses Maß an Homogenität in den Merkmalsverläufen aufweisen, um als Trainingsdaten dienen zu können. Hierfür wurden modifizierte Kugellager der markierten Einbauposition bis zum Fehlerfall betrieben. Aufgrund der qualita-

tiv hochwertigen Bauweise waren Versuche, das Lager durch Dauerbelastung mit keiner oder geringer Vorschädigung und unter Einbringung von Unwuchten zum mechanischen Versagen zu bringen, nicht erfolgreich. Erst die Kontaminierung mit synthetischen Industriediamanten führte im Durchschnitt nach ~100 Betriebsstunden zum Ausfall des Prüflings. Hiermit soll der Fehlerfall eines Eintrages von Partikeln durch kontaminiertes Schmiermittel simuliert werden:




Abbildung 77: Vorgehensweise zur Lagerbeschädigung: (a) Demontiertes Lager, (b) Geöffnetes Lager zur Einbringung von synthetischen Industriediamanten

Durch die Vorgehensweise während der Demontage und des Wiedereinbaus sowie der Einbringung einer messbaren Menge an synthetischen Diamanten (1 mg / Versuch) soll die Vergleichbarkeit der Ergebnisse ermöglicht werden.

Durch eine visuelle Inspektion der Lager und des Prüflings nach dem Ausfall lässt sich die Versagensart auf ein unzulässig großes Lagerspiel zurückführen, das durch den erhöhten Abrieb infolge der Kontamination mit den Diamanten verursacht wird und zum Schleifen zwischen Rotor und Gehäuse, bzw. Rotor und Stator führt:




Abbildung 78: Fehlerfall nach Kontaminierung mit synthetischen Diamanten: (a) Abrieb der rechten inneren Lagerauflagefläche, (b) Schleifpunkte des Rotors durch erhöhtes Lagerspiel

Der erhöhte mechanische Widerstand durch das Schleifen zwischen Rotor / Stator und Rotor / Gehäuse führt aufgrund der zusätzlich benötigten Antriebsleistung zu einem Anstieg des Stromverbrauches und damit auch der Temperatur der Spulenwicklungen des Stators. Zur Vermeidung von dauerhaften Schäden am Motor wird dieser daraufhin beim Überschreiten von zulässigen Maximalwerten der Stromaufnahme oder internen Temperatur durch einen integrierten Überlastschutz

abgeschaltet. Der Zeitpunkt der automatischen Abschaltung des Prüflings wird als EoL des jeweiligen Testlaufes interpretiert.

6.4.1. Prüfstandsaufbau und Messdatenerfassung

Für einen repräsentativen Betrieb des Lüfters sind im Wesentlichen eine möglichst homogene Anströmung am Einlass und ein Druckwiderstand entsprechend des Auslegungspunktes (s. Anhang D) zu gewährleisten. Das verwendete Rohrleitungssystem soll diese Anforderungen unterstützen. Die Regelung des Druckwiderstandes erfolgt mittels einer Blende und einer Durchflussmessung, mit dem Ziel, den gemessenen Durchfluss mit der regelbaren Blendenfläche an den geforderten Wert im Auslegungspunkt anzupassen. Der Auslass stellt sicher, dass der Luftstrom kontrolliert abgelassen werden kann. Die Instrumentierung des Prüflings ermöglicht neben der Spannungsversorgung mit 115 VAC auch eine Messung der Motordrehzahl und den Beschleunigungen des Motorgehäuses in den drei Hauptachsen:

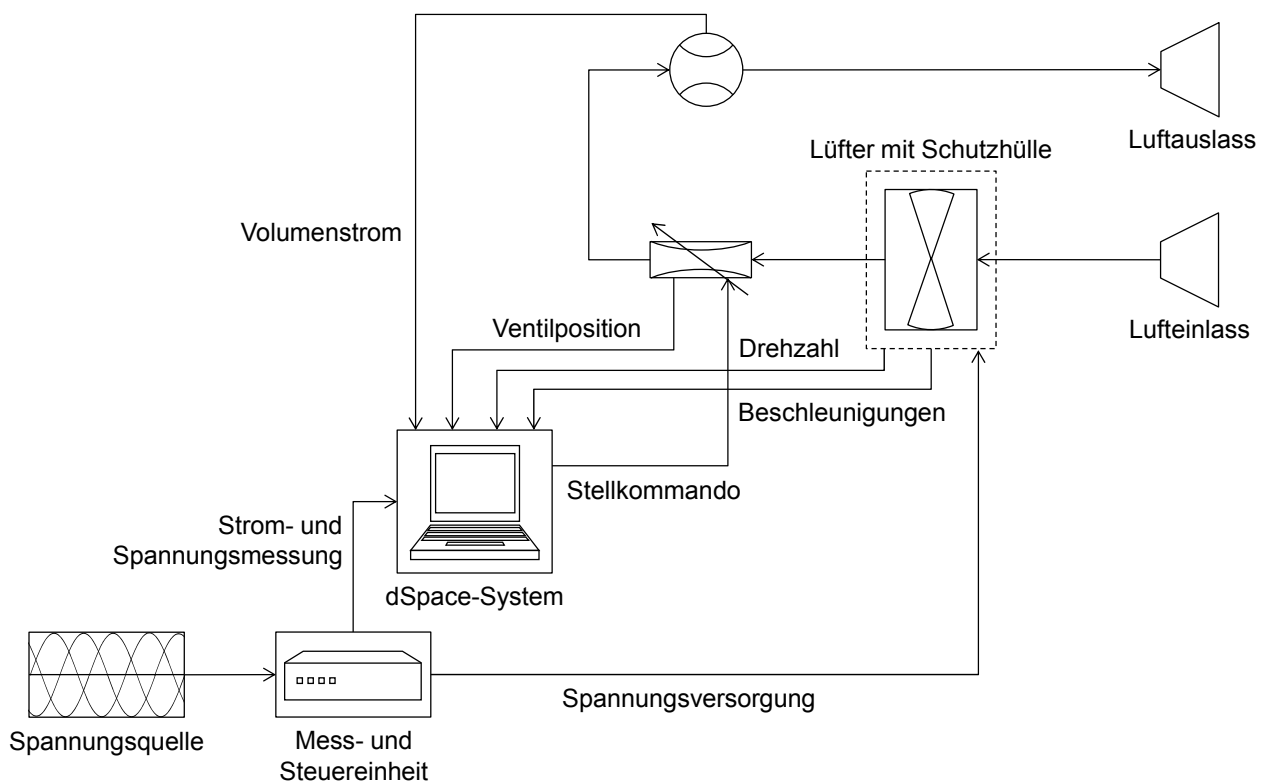


Abbildung 79: Prinzipskizze Prüfstandsaufbau und Messdatenerfassung

Die Messdatenerfassung erfolgt durch ein dSpace-System, mit dem die Drehzahl des Motors, der Stromverbrauch jeder Phase, die Blendenöffnungsposition sowie der Durchfluss und über piezoelektrische Sensoren mit einem nachgelagerten Kupplermodul auch die Beschleunigung des Gehäuses in den drei Hauptachsen aufgezeichnet werden. Zur Regelung des Betriebsverhaltens des Lüfters wird mit dem Volumenstrom als Regelgröße über die Blende der Druckwiderstand des Rohrleitungssystems kontrolliert. Aufgrund der begrenzten Anzahl an Testreihen wurden alle Tests mit

konstanter Blendenöffnung im Auslegungspunkt des Lüfters durchgeführt. Da weiterhin die Drehzahl des Lüfters aufgrund der Motorbauweise und der konstanten Netzfrequenz von 400 Hz über alle Versuche annähernd konstant bleibt, sind für die Verifikation des Prognosekonzeptes nur der eigentliche CI und die Zeitpunkte der Messdatenerfassung von Interesse.

Eine direkte Messung der Schadensgröße ist mit den verfügbaren Signalen nicht möglich. Für einen wiederholten Aus- und Einbau zur Bewertung des Zustandes hätte das Lager geöffnet und die Oberflächen der Laufringe und Wälzkörper untersucht werden müssen, wodurch die abgelagerte Menge, der Zustand und die Verteilung des kontaminierten Schmiermittels und somit auch das Degradierungsverhalten beeinflusst worden wären. Um dennoch brauchbare Datensätze für die experimentelle Verifikation zu erhalten, wurde ein alternativer Ansatz gewählt:

Allgemeingültig kann für Kugellager eine starke Korrelation zwischen der Schadensausprägung und dem auftretenden Vibrationsspektrum angenommen werden [69], [122]. Für eine Fehlerdiagnose werden hierbei üblicherweise die Amplituden spezifischer Frequenzen bewertet [123]. Diese verlieren jedoch bei zunehmender Schadensgröße an Aussagekraft, da sie auf der Messung eines diskreten Impulses als Funktion der Lagergeometrie und der Drehzahl basieren. Sobald der Schaden an einem der Laufringe oder Wälzkörper nicht mehr als diskret betrachtet werden kann, sind einzelne Frequenzen nicht mehr geeignet den Zustand vollständig zu beschreiben²⁸.

Um alle Informationen des Beschleunigungssignals zu nutzen, wird das komplette Spektrum aller drei Hauptachsen im Zeitbereich betrachtet. Die Datenerfassung erfolgt alle 180 Sekunden über eine Dauer von 5 Sekunden mit jeweils 25 kHz Abtastrate pro Achse. Zur Vermeidung von Aliasing-Effekten wird entsprechend des Shannon-Kriteriums²⁹ im Kupplermodul ein analoges Tiefpassfilter mit einer Eckfrequenz von 10 kHz verwendet. Die Erfassung und Aufbereitung der Daten ermöglicht für die Ansprechschwelle der Beschleunigungssensoren ein Signal-Rausch-Verhältnis von ~30 dB, mit einem Effektivwert, der deutlich über der Ansprechschwelle liegt (Verhältnis von Ansprechschwelle und Effektivwert $\sim 10^{-3}$). Somit ist durch die Mechanik oder Elektronik induziertes Signalrauschen vernachlässigbar.

²⁸ Für die Fehlerprognose ist die Diagnose mittels der diskreten Lagerfrequenzen lediglich geeignet, um die Art des Schadens und den Startpunkt der Degradierung zu bestimmen.

²⁹ Während für eine digitale Filterung das Nyquist-Kriterium verwendet werden kann (Abtastfrequenz Faktor ~ 2 größer als die höchste Frequenz im betrachteten Spektrum), ist für analoge Filter kein idealer Amplitudenabfall außerhalb des betrachteten Bandes möglich. Deswegen ist nach dem Shannon-Kriterium für die Nutzung des analogen Tiefpassfilters die Abtastfrequenz um den Faktor $\sim 2,56$ größer als die gewünschte Eckfrequenz zu wählen, bzw. bei vorgegebener Abtastrate die Filterauslegung entsprechend vorzunehmen.

6.4.2. Vorgehensweise zur Datenaufbereitung

Ein Beschleunigungssignal weist ein stochastisches Verhalten mit periodischen Anteilen auf, die durch die Systemeigenschaften und Betriebsbedingungen bestimmt werden. Wenn die gemessenen Werte einen annähernd konstanten Mittelwert aufweisen, kann zur Analyse der Amplituden die Standardabweichung der Messwerte verwendet werden [124]. Anders als bei der Nutzung des Effektivwertes wird durch die Standardabweichung ein systematischer Fehler in den Messdaten korrigiert. Für eine Messung ohne systematischen Fehler entspricht die Standardabweichung dem Effektivwert.

Um die Analyse der Degradierungsverläufe unabhängig von systematischen Fehlern bei der Datenerfassung zu ermöglichen, wird zur Herleitung des CI die Standardabweichung der Vibrationssignale genutzt. Die Messdauer von 5 Sekunden ist im Vergleich zur gesamten Länge einer Messreihe hinreichend klein um den Trend durch die Degradierung zu vernachlässigen (Verhältnis von Messzeit und Testdauer $\sim 10^{-5}$). Die Standardabweichung σ_{ai} der Messung über die angegebene Dauer von 5 Sekunden wird jeweils als einzelner Datenpunkt behandelt.

Um alle Informationen der Beschleunigungen in den drei Achsen (σ_{ax} , σ_{ay} und σ_{az}) zu berücksichtigen, wird zunächst die Resultierende σ_{aR} bestimmt:

$$\sigma_{aR} = \sqrt{\sigma_{ax}^2 + \sigma_{ay}^2 + \sigma_{az}^2} \quad (8.23)$$

Aus den durchgeführten Testläufen ergeben sich insgesamt sechs individuelle Trends für σ_{aR} , die eine Grundlage zur Entwicklung von Prognosefähigkeiten bieten:




Abbildung 80: Experimentelle Daten: (a) Resultierende der Standardabweichung mit gefilterten (rot markiert) und ausgewählten (grün markiert) Anteilen, (b) Verlauf des CI für Trainingsdatensatz

Die restlichen Verläufe weisen eine zu große Variabilität auf um als Teil des Trainingsdatensatzes verwendet werden zu können. Eine mögliche Ursache für die große Variabilität in den beobachteten Verläufen könnte die Inhomogenität der Materialeigenschaften von den verwendeten Diamanten sein. Die geforderten Nachweise während der Fertigung und Abnahme der synthetischen Diamanten sind nicht vergleichbar mit den hohen Qualitätsanforderungen für die Produktion und Beschaffung

des Lüfters und seiner Einzelteile, weswegen die Ursache für das stochastische Ausfallverhalten eher bei dem verwendeten Diamantenstaub als der Lüfterauslegung vermutet werden kann. Des Weiteren konnte während der Versuchsreihen nachgewiesen werden, dass der nur aus Kunststoff bestehende Lagerkäfig durch die erhöhten Temperaturen infolge der mechanischen Reibung für unterschiedliche Testreihen auch unterschiedlich stark beschädigt wurde, womit nicht über die gesamte Testdauer sichergestellt werden konnte, dass die Menge an Diamantenstaub von Beginn der Messreihe bis zum Komponentenausfall auch in allen Lagern identisch war.

Deutlich sind am Anfang mehrerer Verläufe erhöhte Vibrationspegel zu erkennen, deren Amplitude nach unterschiedlichen Laufzeiten wieder abnimmt. Dieser Anstieg ist ein Indikator für die Sprödigkeit der synthetischen Diamanten, die nach einer Einlaufzeit in feinere Partikel zermahlen worden sind und den Abrieb des Lagers beschleunigen, bis wie in § 6.4 beschrieben das erhöhte Lagerpiel zu einer Abschaltung des Prüflings führt. Weil das Vibrationssignal nur ein Indikator für den Zustand des Lagers ist, aber nicht benutzt wird um den Versuch zu unterbrechen, führt die Materialvariabilität und der Einfluss der unterschiedlichen Betriebs- und Umgebungsbedingungen (Verteilung der Diamanten im Lager und Temperaturschwankungen) zu unterschiedlichen Maximalniveaus der gemessenen Beschleunigungen. Somit bietet der experimentelle Datensatz eine gute Grundlage um die Verteilung PoF_{CI} auch mit realen Daten Umständen bestimmen zu können.

Der Verlauf der resultierenden Standardabweichung σ_{aR} wird durch ein eindimensionales lineares Gauß-Filter [125] geglättet. Zur Vermeidung von Diskontinuitäten bei der Filterung wird das Signal hierfür zunächst linksseitig durch eine symmetrische und rechtsseitig durch eine Extrapolation erweitert. Die Faltung entsprechend [125] erfolgt mit der eindimensionalen, über den Ursprung zentrierten Dichtefunktion für Normalverteilungen mit fixen Parametern, die empirisch optimiert wurden. Die gefilterten Verläufe weisen aufgrund von nicht rekonstruierbaren Einflüssen während der Testreihen (aufgrund der Dauer der Testreihen wurden die Abläufe weitestgehend automatisiert, weswegen die Umgebungsbedingungen während der Tests nicht immer bekannt sind) abschnittsweise ein Verhalten auf, dass die Bewertung der Prognosefähigkeit nachteilig beeinflussen kann, weswegen zusätzlich eine Interpolation über die gefilterten Verläufe vorgenommen wurde.

Startpunkt der Verläufe, die dann eine Grundlage für die Herleitung des CI bilden, ist jeweils der Zeitpunkt, ab dem ein weitestgehend monotoner Anstieg der gemessenen Standardabweichung σ_{aR} zu beobachten ist. Alle Anteile vor dem gewählten Startpunkt der genutzten Teilverläufe werden durch die Einlaufbedingungen der Diamanten bestimmt und sind kein Effekt der Schadensausprägung, da ansonsten kein dauerhafter Abfall der Amplitude zu beobachten wäre.

Damit wird die beschriebene Unterscheidung zwischen Diagnose und Prognose (s. § 5.1) getroffen und nur der Anteil für die Verifikation des Prognosekonzeptes genutzt, der den Verlauf der Schadensgröße abbildet und die Betriebsdauer bis ein Schaden entsteht nicht berücksichtigt.

Da die Abstände zwischen der Erfassung von zwei Messdatensätzen während der Testläufe nicht immer für alle Testreihen identisch, bzw. konstant waren, mussten die Datenpunkte anhand der mitgelieferten Zeitschriebe in einen entsprechenden zeitlichen Verlauf konvertiert werden. Der verwendete CI wird schließlich nach der Beseitigung des Einflusses verschiedener Grundniveaus der Vibrationspegel unterschiedlicher Testläufe aus der Normierung dieser Verläufe mit dem Mittelwert der maximal auftretenden Werte σ_{aRmax} über alle Verläufe gebildet:

$$CI_{i,k} = \frac{\hat{\sigma}_{aRi,k}}{\bar{\sigma}_{aRmax}} \cdot 100 \quad (8.24)$$

wobei:

$$\hat{\sigma}_{aRi,k} = \sigma_{aRi,k} - \arg \min_{\sigma} \{ \sigma_{aRi} \} \quad (8.25)$$

$$\bar{\sigma}_{aRmax} = \frac{1}{N} \cdot \sum_{i=1}^N \arg \max_{\sigma} \{ \hat{\sigma}_{aRi} \} \quad (8.26)$$

mit:

N = Anzahl an Testläufen

Der Trainingsdatensatz für die experimentelle Verifikation besteht somit aus den zeitlichen Verläufen des CI ohne zusätzliche äußere Betriebsbedingungen. Die Vorgehensweise zur Aufbereitung der gemessenen Daten kann hierbei als Diagnosealgorithmus interpretiert werden, um die Bewertung der Prognose nicht durch die Wahl eines ungeeigneten CI zu beeinflussen.

6.4.3. Bewertung der Prognosefähigkeiten

Aufgrund der geringen Anzahl an Verläufen wurde jeweils mit einem Teildatensatz trainiert und die Verifikation der Prognosefähigkeiten an dem gesamten Datensatz (inklusive der für das Training verwendeten Verläufe) durchgeführt. Hiermit wird neben der rein statistischen Analyse durch die synthetischen Verläufe auch das Verhalten bei der Nutzung identischer Degradierungsmerkmale analysiert und somit neben dem Nachweis der Prognoseeigenschaften für reale Messdaten auch die Fähigkeit dargestellt, einen bereits bekannten Verlauf möglichst exakt wiederzugeben. Zur Illustration des Prognoseverhaltens sind drei Trainingsdatensätze ausgewählt worden:

Testfall 1: Training mit Einzelverlauf aus dem Mittelfeld aller Messreihen (Test #3).

Testfall 2: Training mit 50 % der Daten, die das Datenfeld begrenzen (Test #3, Test #5, Test #6).

Testfall 3: Training mit allen verfügbaren Datensätzen.

Die Verläufe der Systemidentifikation und die durch die Systemidentifikation erreichten Werte der Bewertungskriterien der letzten Generation sind in Abbildung 81 dargestellt.

Während für alle Trainingsdatensätze bis auf Kriterium F4 eine konsistente Filterauslegung möglich war, ist für den ersten Datensatz, mit nur einem Verlauf als Trainingsdatenanteil, ein nahezu perfektes Ergebnis erzielt worden. Neben einer konsistenten Filterauslegung ist auch der Prognosefehler über den gesamten Wertebereich vernachlässigbar klein und ermöglicht eine konstant zuverlässige Qualität der Prognose:

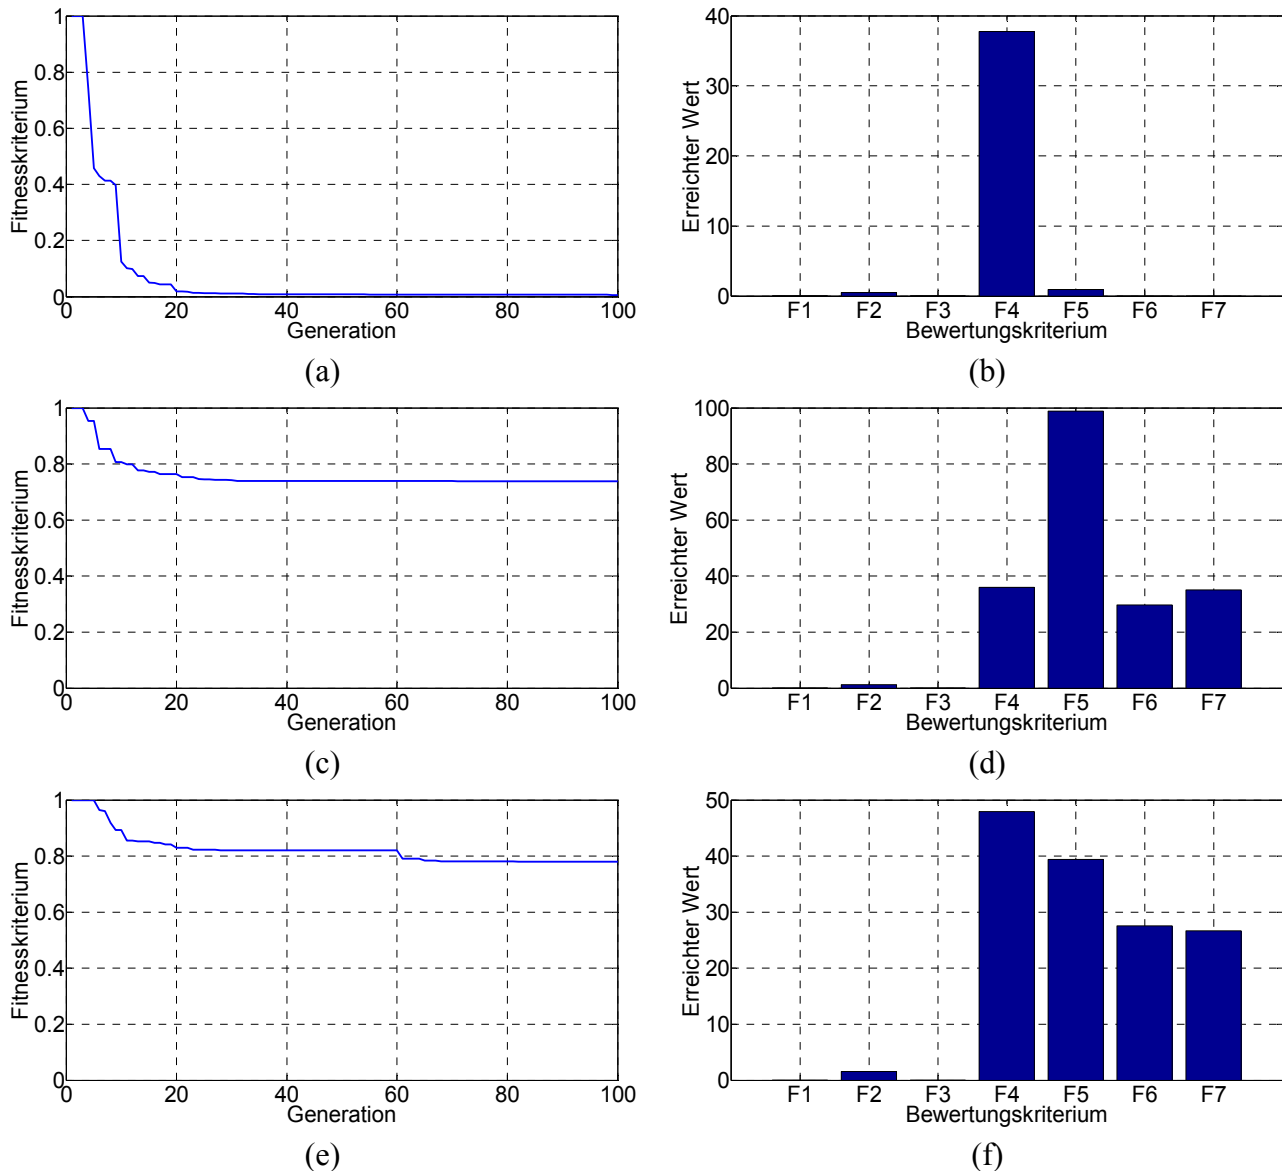


Abbildung 81: Fitnessverlauf über Systemidentifikation und Anteile der Bewertungskriterien für letzte Generation der Prognosefunktion für experimentelle Daten: (a), (b) Testfall 1, (c), (d) Testfall 2 (e), (f) Testfall 3

Die Ergebnisse für die prognostizierten Einzeltrajektorien (s. [Abbildung 82](#)) zeigen ebenfalls, dass der Verlauf von Testfall #1 idealisiert wiedergegeben werden kann. Nicht nur der Ausfallzeitpunkt, sondern der gesamte Verlauf des gewählten CIs kann exakt vorhergesagt werden. Durch diese Beobachtung motiviert, wird die Schlussfolgerung aufgestellt, dass der GP-UKF-Ansatz bei einer eindeutigen Zuordnung von Trainings- und Testdaten beliebige Verläufe vergleichsweise exakt prognostizieren kann.

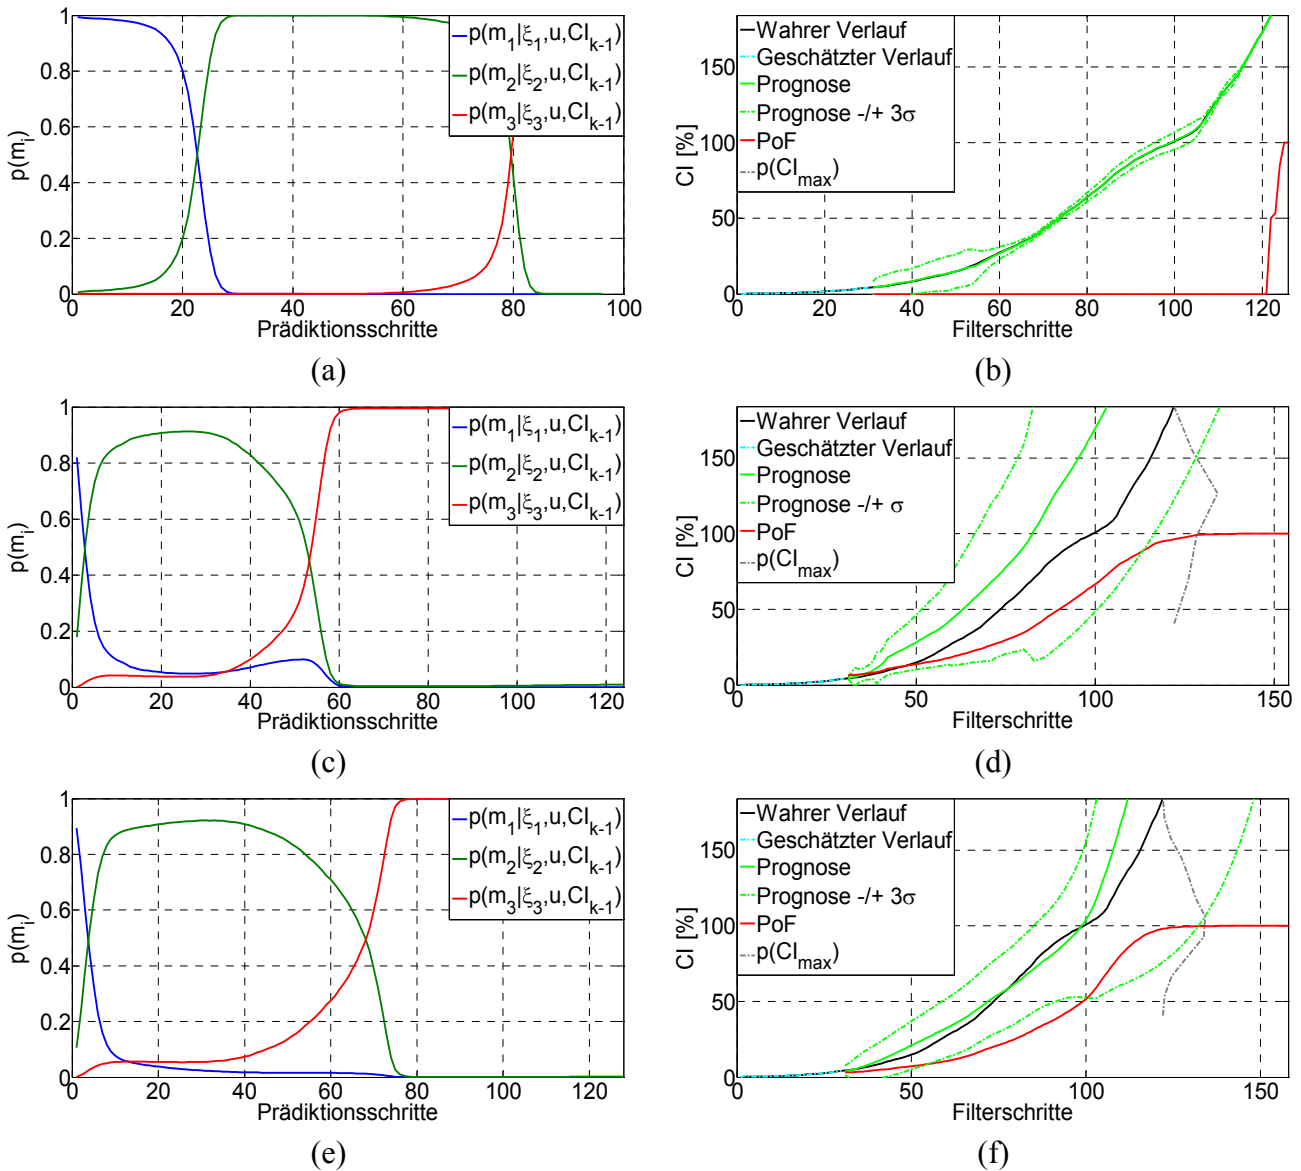


Abbildung 82: Modellgewichtungen und Einzeltrajektorie der Prognosephase mit $t_0 = 0,25 \cdot \lambda$ für experimentelle Daten: (a), (b) Testfall 1, (c), (d) Testfall 2, (e), (f) Testfall 3

Durch die Reduzierung auf einen Merkmalsverlauf werden durch die Störgröße ξ keine nennenswerten Beiträge zur Propagierung von Unsicherheiten geliefert, weswegen die Vorhersage des Einzelverlaufes mit entsprechend hoher Genauigkeit und Präzision realisiert werden kann. Bei einem Modellwechsel (Prädiktionsschritte ~ 20 und ~ 80 in Abbildung 82 (a) und entsprechend Filterschritte ~ 40 und ~ 100 in Abbildung 82 (b)) ergibt sich durch die Divergenz der Modelle, die ihren Wertebereich verlassen, eine vorübergehende Zunahme der prognostizierten Varianz. Durch den IMM-Ansatz wird diese bis zur Stabilisierung der Modellgewichtung auf die Verteilung $p(CI|u)$ übertragen (s. Abbildung 83 (a)). Die Reinitialisierung mit den gewichteten Modellwerten verhindert jedoch eine Divergenz des Gesamtergebnisses und nach dem Übergang auf das für den jeweiligen Abschnitt gültige Modell verläuft die Propagierung wieder stabil und ohne eine überhöhte Unsicherheit.

Diese Beobachtung lässt vermuten, dass bei einer Divergenz der Teilmodelle außerhalb ihres Gültigkeitsbereiches ein SM-Ansatz zu bevorzugen ist.

Bei einer Erweiterung des Trainingsdatensatzes ist dieses Verhalten nicht mehr zu beobachten, da die Teilmodelle zunehmend auch außerhalb des jeweiligen Datenbereiches eine gewisse Gültigkeit besitzen (s. [Abbildung 83](#) (b), Testfall 3 weist ein ähnliches Verhalten auf). Dafür variieren der Erwartungswert und die Vertrauensbereiche der propagierten Verteilung $p(CI|u)$. Die Zunahme der Unsicherheiten resultiert hauptsächlich aus der erhöhten Anzahl an Datenpunkten zur Herleitung der statistischen Momente der Störgröße ξ , während der Erwartungswert durch die Berücksichtigung von weiteren Teilverläufen zur Modellidentifikation beeinflusst wird. Bei weiterer Erhöhung der verfügbaren Trainingsdatensätze (Testfall 3) stabilisiert sich die Propagierung der Unsicherheiten, da der Mittelwert der Merkmalsverläufe zunehmend dem Zentralwert entspricht.

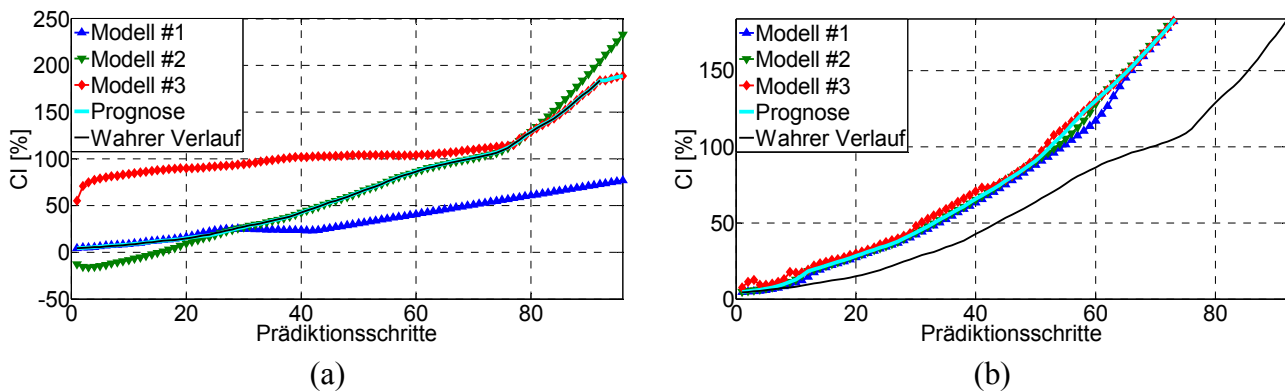


Abbildung 83: Verlauf der Teilmodelle in Prognosephase mit $t_0 = 0,25 \cdot \lambda$ für experimentelle Daten: (a) Testfall 1, (b) Testfall 2

Die Ergebnisse des gemittelten Prognosefehlers zeigen, dass der GP-UKF-Ansatz trotz der großen Variabilität in den Verläufen und individuellen Grenzwerten der gemessenen Beschleunigungen eine robuste Prognose ermöglicht (s. [Abbildung 84](#) und [Abbildung 85](#)).

Das Optimierungspotential des Korrekturfaktors ist wie auch für die synthetischen Daten abhängig von der Vergleichbarkeit der Trainings- und Verifikationsdatensätze. Aufgrund der großen Variabilität in den gemessenen Verläufen ist dieser Effekt bei den experimentellen Messwerten deutlicher als bei den synthetischen Daten, die innerhalb eines Parametersatzes der Modelle eine größere Homogenität der Verläufe aufweisen. Da für den ersten Testfall mit nur einem Trainingsdatensatz der Prognosefehler über den identischen Validierungsdatensatz vernachlässigt werden kann, ist der Einfluss des Korrekturfaktors ebenfalls vernachlässigbar. Durch die Anpassung der identifizierten Modelle an eine Einzeltrajektorie können die anderen Verläufe nur mit großen Abweichungen von der Ideallinie prognostiziert werden.

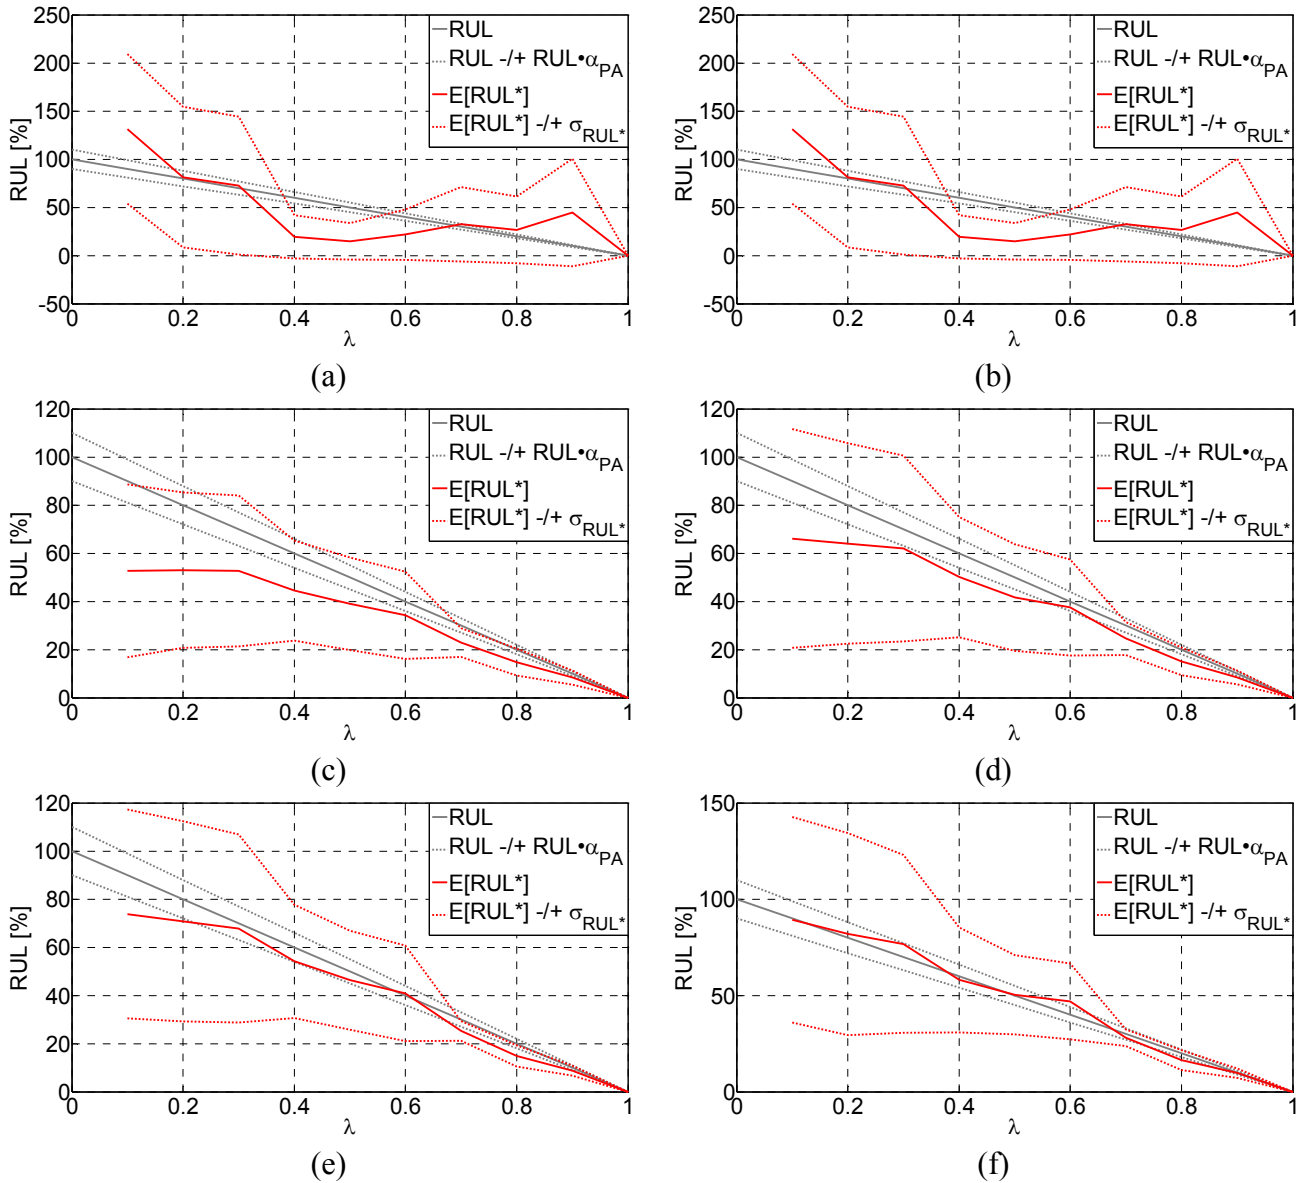


Abbildung 84: Erwartungswert und Standardabweichung des Prognosefehlers für experimentelle Daten mit und ohne Korrekturfaktor: (a), (b) Testfall 1, (c), (d) Testfall 2, (e), (f) Testfall 3

Für den zweiten Testfall mit drei Trainingsdatensätzen lässt sich für die Bestimmung des mittleren Fehlers bereits ein wesentlich besseres Ergebnis erzielen. Da der Verifikationsdatensatz alle Verläufe, der Korrekturfaktor jedoch nur das Wissen des Trainingsdatensatzes enthält, ist durch diesen zunächst keine nennenswerte Verbesserung möglich.

Für den dritten Testfall, bei dem der Trainingsdatensatz und der Verifikationsdatensatz identisch sind, wird der mittlere Fehler weiter reduziert und durch den Korrekturfaktor, der jetzt alle Informationen der sechs Verläufe zur Verifikation beinhaltet, eine optimierte Prognose mit reduziertem mittlerem Fehler ermöglicht. Anhand dieser Evaluierung lässt sich der Einfluss einer Verbesserung der Trainingsdatenbasis veranschaulichen. Sowohl die Qualität der eigentlichen Prognose als auch das Optimierungspotential des Korrekturfaktors lassen sich für den GP-UKF-Ansatz mit der Anzahl und Repräsentativität der Trainingsdaten kontinuierlich steigern.

Anhand der gemittelten Vertrauensbereiche lässt sich die Stabilisierung der Unsicherheiten bei der Prognose durch die Nutzung aller verfügbaren Testdaten bestätigen:

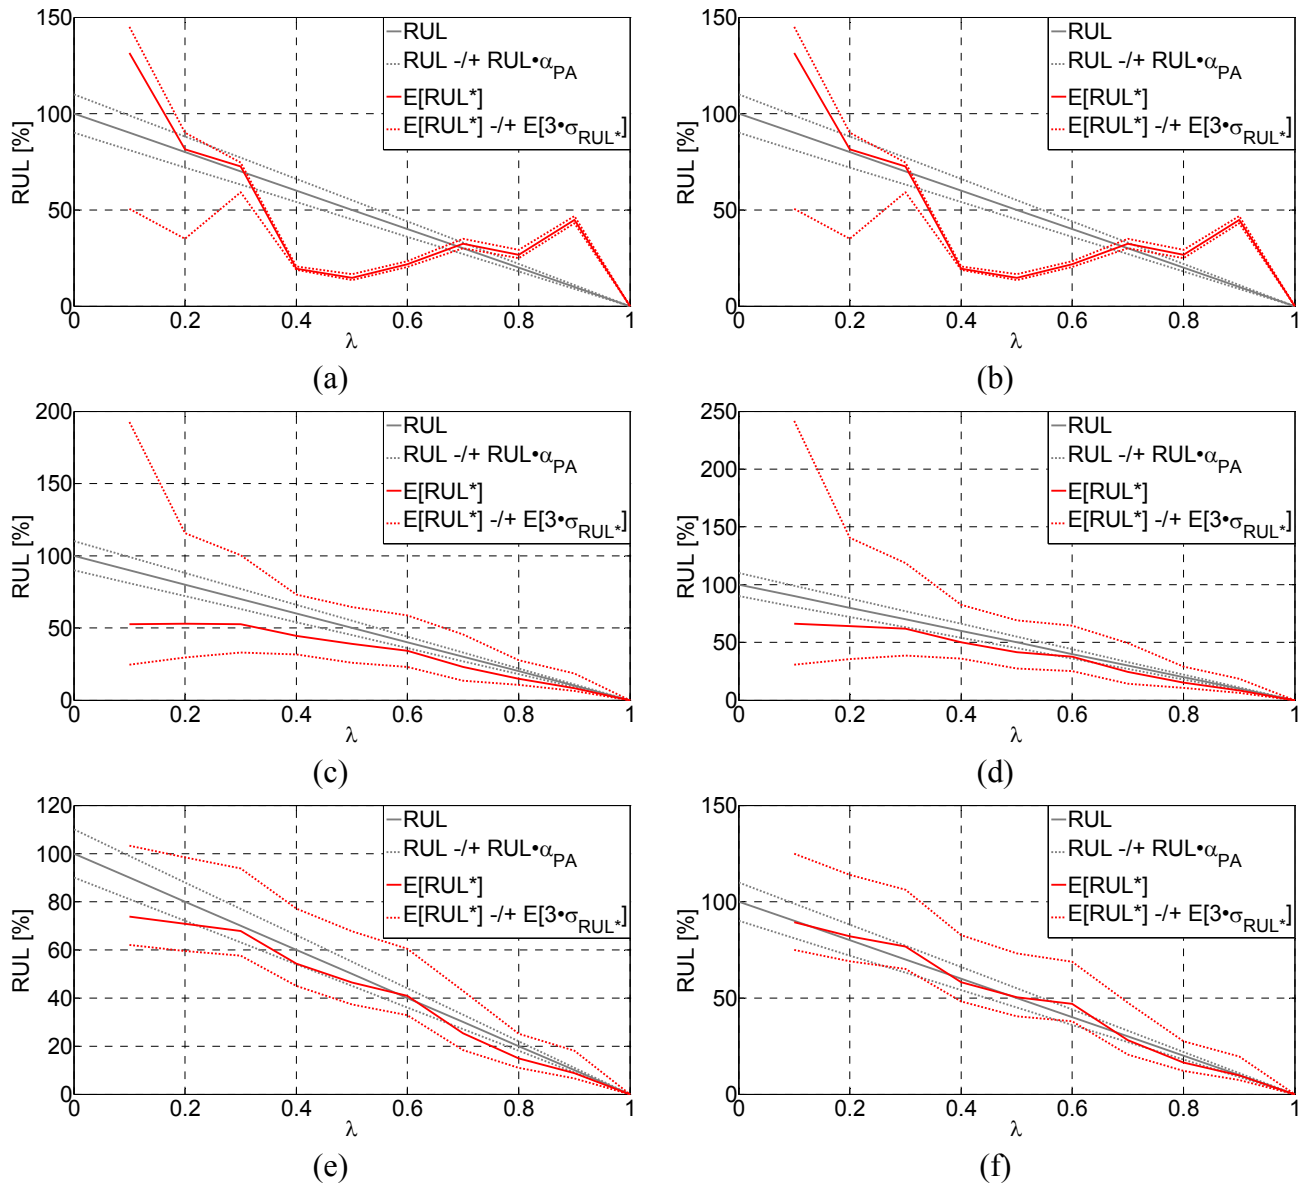


Abbildung 85: Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose für experimentelle Daten mit und ohne Korrekturfaktor: (a), (b) Testfall 1, (c), (d) Testfall 2, (e), (f) Testfall 3

Die erhöhte Unsicherheit für Testfall 1 bei Startpunkten der Prognose mit $t_0 \leq 0,3 \cdot \lambda$ resultiert aus der Divergenz der oberen Vertrauensbereiche, wenn die Teilmodelle außerhalb ihres Gültigkeitsbereiches eine zu hohe Gewichtung erhalten. Die Überhöhung der Modellgewichtung aus den Trainingsdaten resultiert aus der Verteilungsform der empirischen Dichteverteilung, die auch außerhalb des verwendeten Datensatzes noch Wahrscheinlichkeiten mit $p(m_i|u) > 0$ zulässt, um Diskontinuitäten bei den Modellwechseln zu vermeiden.

Wie aus [Abbildung 86](#) (a) ersichtlich, lässt sich bei Verwendung von nur einem Trainingsverlauf bei Anwendung auf dieselbe Einzeltrajektorie für jeden Startpunkt eine optimierte Prognose erzielen (s. Verlauf für Test #3). Für die anderen Trajektorien wird, wie bereits in [Abbildung 84](#) (a), (b)

und [Abbildung 85](#) (a), (b) dargestellt, aufgrund des limitierten Wissens während der Systemidentifikation kein brauchbares Ergebnis für die Vorhersage des Ausfallzeitpunktes erreicht. Dieses Ergebnis resultiert aus der Inhomogenität der verwendeten Datensätze. Bei hinreichender Homogenität der Trainingsdaten sollte ebenfalls bei Verwendung von nur einem Datensatz für die Systemidentifikation für die anderen Verläufe eine brauchbare Prognose möglich sein.

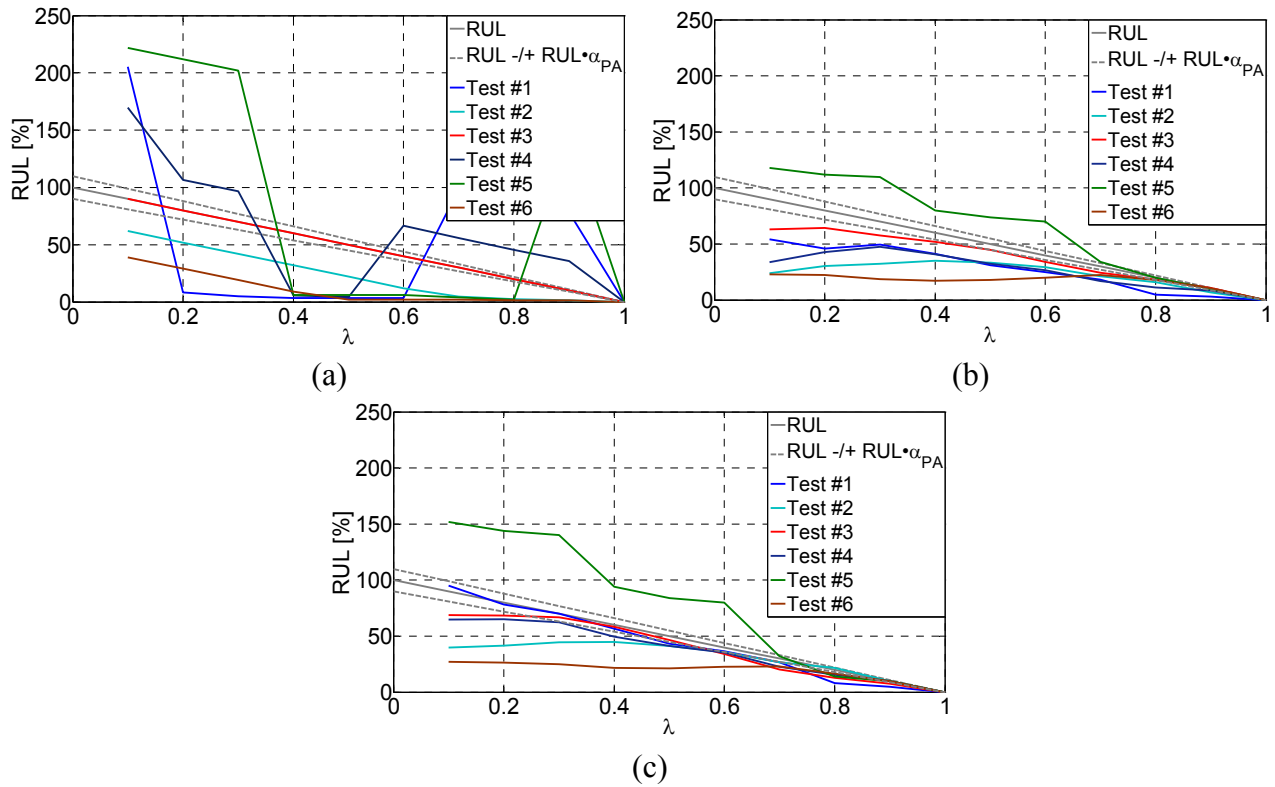


Abbildung 86: Erwartungswert des Prognosefehlers für experimentelle Daten: (a) Testfall 1, (b) Testfall 2, (c) Testfall 3

Für Testfall 2 wird, wie bereits aus [Abbildung 84](#) (c), (d) und [Abbildung 85](#) (c), (d) ersichtlich, die Prognosequalität auch für die anderen Teilverläufe optimiert. Da die verwendeten Trainingsdaten die Randbereiche des Messdatensatzes abbilden, wird für alle Verläufe eine Konvergenz der Prognosequalität ermöglicht.

Bei Verwendung aller Trainingsdatensätze (Testfall 3) reduziert sich der Prognosefehler für das Mittelfeld der Messdaten (Test #1-#4) und weist für die Randbereiche (Test #5 und #6) eine entsprechend große Abweichung von der Ideallinie auf. Die Abweichung für Test#6 ist hier sogar größer als bei Testfall 2, da die Gewichtung jeder Einzeltrajektorie bei Testfall 3 nur ~17% ausmacht, während Test #5 bei Testfall 2 ~33% des Trainingsdatensatzes entspricht. Somit zeigt der reduzierte Fehler für die Randbereiche von Testfall 2 gegenüber Testfall 3 das durch den jeweiligen Trainingsdatensatz implizit erwartete Verhalten.

Aus den dargestellten Verläufen der Verifikationstests ergeben sich folgende Kennzahlen zur Bewertung der Prognoseeigenschaften:

Bewertungskriterium	Testfall 1	Testfall 2	Testfall 3
S1 – Prognosehorizont [λ]	0,81	0,69	0,55
G1 – Mean Absolute Percentage Error [%]	115,8	36,9	29,4
G2 – False Negatives [%]	83,3	112,9	91,7
G3 – False Positives [%]	41,7	16,7	16,7
G4 – Prognostic Accuracy [λ]	0,85	0,76	0,71
P1 – Probability of Error [%]	68,5	0	0
P2 – Prognostic Precision [λ]	0,85	0,54	0,35
P3 – Sample Standard Deviation [%]	24,5	16,4	14,3
K1 – Local Convergency [λ]	0,61	0,45	0,49

Tabelle 17: Bewertung der Prognoseleistungsfähigkeit des GP-UKF-Ansatzes für experimentelle Trainingsdatensätze

Im Mittel ist für die Kriterien S1, G1 und P3 wie erwartet mit der Zunahme der verwendeten Trainingsdatensätze auch eine Verbesserung der Prognose zu beobachten. Das unerwartete Verhalten von G2 ist auf die große Variabilität der Einzelverläufe und die geringe Anzahl an Messdaten zurück zu führen, da bei einem Anteil von $\sim 17\%$ ein ungünstiger Einzelverlauf das Ergebnis auch entsprechend beeinflussen kann. Daraus lässt sich schließen, dass ein mögliches Verbesserungspotential für den GP-UKF-Ansatz darin liegt, die Gültigkeit von Einzeltrajektorien des Trainingsdatensatzes für neue Messdaten besser zu erkennen und die Gewichtung der Anteile der Datenmodule für die prognostizierte Störgröße ξ und zur Modellauswahl $p(m_i)$ entsprechend anzupassen.

Insgesamt liegt die Vermutung nahe, dass der Datensatz an experimentellen Daten aufgrund der geringen Anzahl an vergleichbaren Verläufen und großen Variabilität im Verhalten nur bedingt geeignet ist um eine quantitative Bewertung vorzunehmen. Die qualitative Analyse zeigt jedoch, dass der untersuchte GP-UKF-Ansatz auch für diesen Datensatz eine Prognosefähigkeit zur Verfügung stellt und mit einem Ausbau der Datenbasis zunehmend bessere Ergebnisse liefert.

6.5. Vergleich mit aktuellem Stand der Technik

Für den Vergleich mit einem repräsentativen Konzept aus dem Bereich der hybriden Fehlerprognose wurde der in [52] beschriebene Algorithmus (UKF-GAP) verwendet. Der UKF-GAP nutzt eine Kombination aus hybrider Filterung (IMM), parameterfreier Regression zur Systemidentifikation („Gauß-Prozess“) und rekursiver bayesscher Filterung (UKF) für die Propagierung eines Degradierungsverlaufes unter Berücksichtigung von beliebigen Betriebsbedingungen. Der wesentliche Unterschied zu dem hier untersuchten GP-UKF ist die Vorgehensweise zur Systemidentifikation und Implementierung der Prognosefunktion. Während der GP-UKF-Ansatz das durch die *Genetische Programmierung* hergeleitete modellbasierte Verfahren verwendet, basiert die Systemidentifikation

des UKF-GAP auf einem reinen Datenmodul, das keine Transparenz über die zugrundeliegende Modellstruktur aufweist.

In dem beschriebenen Ansatz dient der *Gauß-Prozess* zur Identifikation eines datenbasierten Moduls für jeden einzelnen Teilverlauf des Trainingsdatensatzes, der UKF zur Filterung von Störgrößen und Prädiktion eines Teilverlaufes und der IMM-Ansatz um bei Verfügbarkeit von mehreren Datenmodulen aus der Systemidentifikation während der Adaptions- und Prognosephase einen gewichteten Mittelwert für die Schätzung und Prognose der Schadensgröße zur Verfügung zu stellen.

Für eine detaillierte Beschreibung des *Gauß-Prozess* zur Systemidentifikation sei an dieser Stelle auf [126] verwiesen. Der IMM-Ansatz entspricht der Beschreibung aus § 4.5.1 und § 5.3.3. Die Implementierung des UKFs ist als Zustandsschätzer entsprechend Anhang A vorgenommen worden. Die Schätzaufgabe besteht analog zum GP-UKF-Ansatz in der Bestimmung der unbekannten Schadensgröße anhand eines Modells für den Gradienten des Merkmalsverlaufes.

Die einzige Änderung gegenüber der Implementierung aus [52] ist die Verwendung einer anderen Kovarianzfunktion für den *Gauß-Prozess* („*Squared Exponential Covariance Function with Automatic Relevance Determination*“ anstelle von „*Isotropic Squared Exponential Covariance Function*“), damit die von den Schadensmodellen verwendeten Eingangsgrößen (hier die skalierten externen Lasten, der Zeitvektor und die Schadensgröße aus dem vorherigen Filterschritt) auch entsprechend genutzt werden können, um die Qualität der Prognose zu steigern [126], [127]. Als Mittelwertfunktion wird ein linearer Ansatz ohne Drift verwendet. Der *Gauß-Prozess* ist durch die Vorgabe der Stützstellen und die Wahl der Kovarianz- und Mittelwertfunktion vollständig definiert.

Die Diskretisierung des Ergebnisraumes wurde durch eine Einteilung in jeweils 1000 Datenpunkte vorgenommen, die als Stützpunkte dienen und zwischen denen der *Gauß-Prozess* die Lösung durch Interpolation mittels der gewählten Kovarianz- und Mittelwertfunktion abbildet.

Für den Vergleich mit dem GP-UKF wird der UKF-GAP mit den Datensätzen der Simulationsmodelle L1-L3 und E1-E3 trainiert. Die unterschiedlichen Eigenschaften der beiden Konzepte werden anhand der einzelnen Bewertungskriterien aus § 6.1 diskutiert und abschließend durch den mit (8.15) gewichteten Gesamtwert verglichen.

6.5.1. Ergebnisse mit UKF-GAP

Der verwendete UKF-GAP liefert für jeden der verwendeten Datensätze eine Prognose, deren Fehler ε_P und Unsicherheit σ_{RUL*} bei der Bestimmung der Verteilung $p(EoP)$ mit Verschiebung des Startpunktes gegen EoL abnimmt. Damit wird die grundlegende Forderung zur Auslegung von Prognosefunktionen aus § 5.1.1 erfüllt:

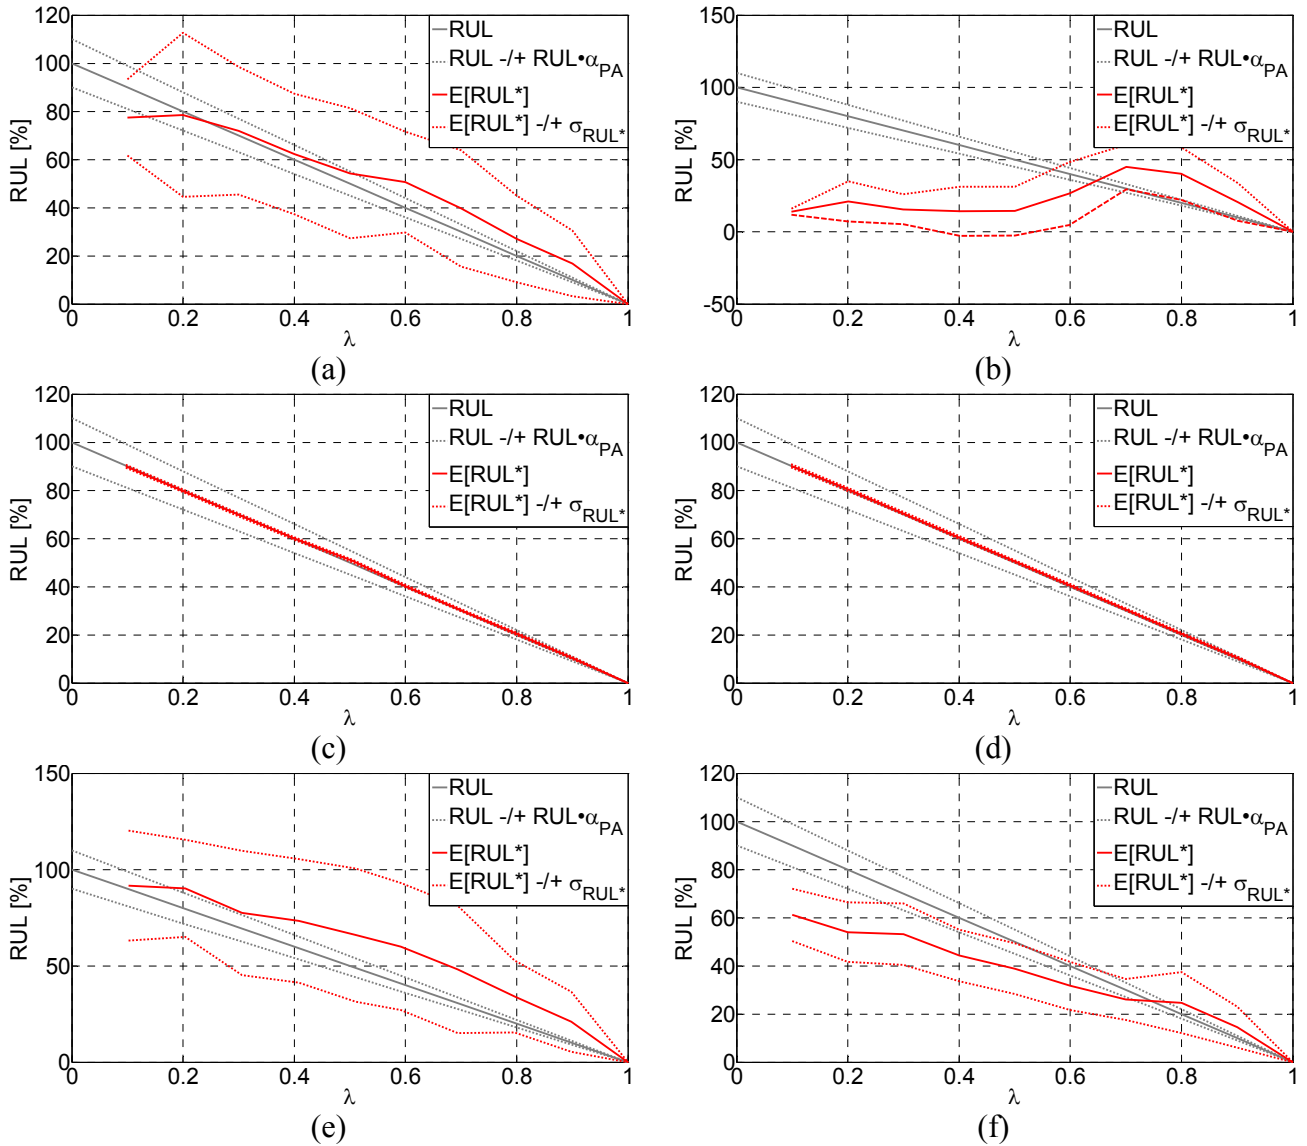


Abbildung 87: Erwartungswert und Standardabweichung des Prognosefehlers für synthetische Trainingsdaten: (a), (c), (e) Schadensmodelle L1-L3, (b), (d), (f) Schadensmodelle E1-E3

Für einzelne Modelle (L1 und L3) divergiert der untere Vertrauensbereich der Verteilung $p(CI|u)$, wodurch die Verteilung $p(RUL^*)$ nicht vollständig abgebildet werden kann.

Während die Verläufe der linearen Schadensmodelle über den Wertebereich $t_0 = [0,1;\dots;0,9]\cdot\lambda$ weitestgehend zuverlässig prognostiziert werden können, ergibt sich für die exponentiellen Anteile besonders für $t_0 \leq 0,5\cdot\lambda$ ein instabiles Verhalten, wodurch keine brauchbare Prognose erzielt werden kann. Lediglich für die Modelle L2 und E2 ist analog zum GP-UKF-Ansatz für jeden Startpunkt eine optimierte Prognose möglich.

Allgemeingültig lässt sich aus den Ergebnissen ableiten, dass der UKF-GAP-Ansatz nur für die linearen Verläufe über den gesamten Wertebereich zur Bestimmung des Erwartungswertes $E[RUL^*]$ geeignet ist, jedoch auch hierbei nur eine begrenzte Stabilität bei der Propagierung von statistischen Eigenschaften besitzt. Der detaillierte Vergleich zwischen GP-UKF und UKF-GAP wird in § 6.5.2 anhand der quantitativen Auswertung der Bewertungskriterien vorgenommen.

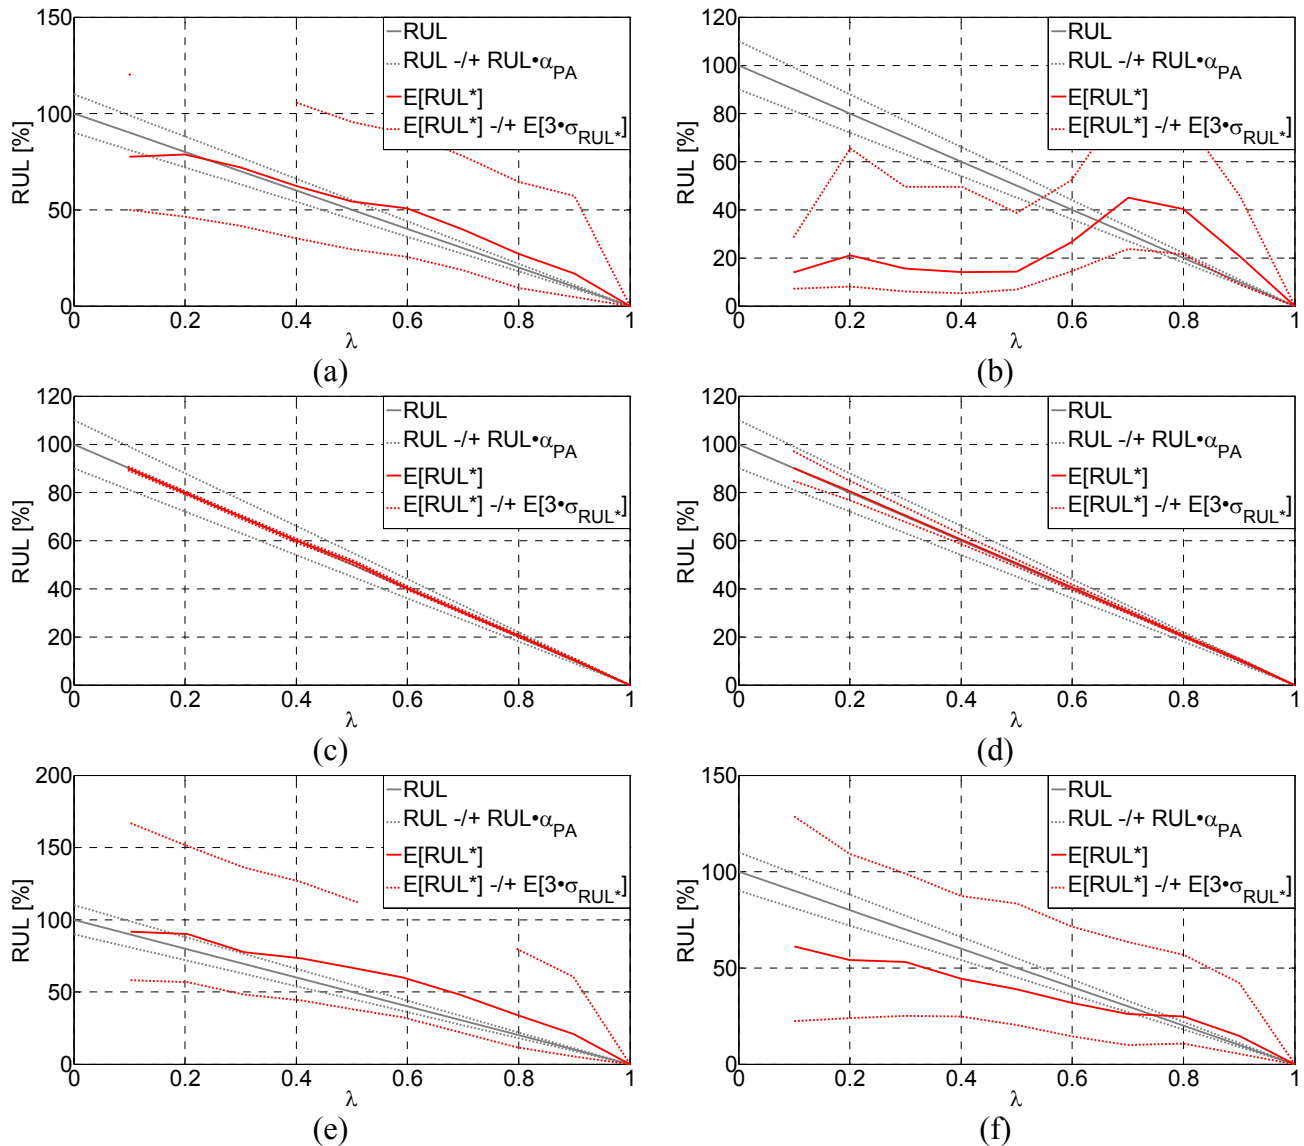


Abbildung 88: Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose für synthetische Trainingsdaten: (a), (c), (e) Schadensmodelle L1-L3, (b), (d), (f) Schadensmodelle E1-E3

Aus den Verläufen der Verifikationstests ergibt sich dann folgende Bewertung der Prognose:

Bewertungskriterium	L1	L2	L3	E1	E2	E3
S1 – PH [λ]	0,83	0,1	0,85	0,91	0,1	0,78
G1 – MAPE [%]	58,7	1,7	79,3	83,1	2,4	43,8
G2 – FN [%]	8,5	0	4,7	11,9	0	12,4
G3 – FP [%]	5,2	0	8,2	4,9	0	2,5
G4 – PA [λ]	0,95	0,1	0,97	0,98	0,1	0,96
P1 – PE [%]	0	0	0	0	0	0
P2 – PP [λ]	0,98	0,1	0,99	0,99	0,1	0,99
P3 – SSD [%]	15,6	0,41	9,2	105,4	0,4	13,1
K1 – LC [λ]	0,58	0,64	0,59	0,51	0,63	0,54

Tabelle 18: Bewertung der Prognose mit UKF-GAP für Schadensmodelle L1-L3 und E1-E3

6.5.2. Vergleich von GP-UKF und UKF-GAP

Für den Vergleich zwischen GP-UKF und UKF-GAP ist das arithmetische Mittel über die Ergebnisse der Prognosekennzahlen aller simulierten Datensätze gebildet worden:

Bewertungskriterium	Mittelwert GP-UKF	Mittelwert GAP-UKF
S1 – PH [λ]	0,45	0,6
G1 – MAPE [%]	23,1	44,8
G2 – FN [%]	4,4	6,3
G3 – FP [%]	2,9	3,5
G4 – PA [λ]	0,63	0,68
P1 – PE [%]	5,2	0
P2 – PP [λ]	0,61	0,69
P3 – SSD [%]	4,2	24,1
K1 – LC [λ]	0,61	0,58

Tabelle 19: Gemittelte Kennzahlen zur Bewertung der Prognoseleistungsfähigkeit von GP-UKF und UKF-GAP für Schadensmodelle L1-L3 und E1-E3

Mit den gemittelten Kennzahlen lässt sich ein Vergleich der beiden Ansätze auch quantitativ durchführen. Hierfür wurden die Ergebnisse ohne Korrekturfaktor verwendet, da durch diesen die direkte Vergleichbarkeit der Ergebnisse nicht mehr möglich gewesen wäre:




Abbildung 89: Vergleich der gemittelten Prognosekennzahlen von GP-UKF und UKF-GAP für synthetische Trainingsdaten

Wie bereits aus der α - λ -Darstellung ersichtlich, liefert der GP-UKF-Ansatz für alle verwendeten Testdatensätze bis auf den Anteil PE ein im Durchschnitt besseres Ergebnis als der UKF-GAP. Weiterhin divergiert für den GP-UKF die Propagierung der Vertrauensbereiche für keinen Testfall, woraus sich schließen lässt, dass durch die zielgerichtete Systemidentifikation die Robustheit der Prognose gegenüber anderen datenbasierten und hybriden Ansätzen insgesamt verbessert werden kann. Die erhöhte PE zeigt ein Verbesserungspotential bei der Propagierung von Unsicherheiten auf, da nicht für alle Teilprognosen gewährleistet werden konnte, dass der wahre Wert RUL innerhalb der Verteilung $p(PoF)$ liegt. Der Anteil von 5% bei 300 analysierten Testfällen liegt allerdings in einem akzeptablen Bereich. Die Differenz des Kennwertes LC lässt sich nicht als absolutes Bewertungskriterium verwenden, da hiermit lediglich der Trend der relativen Genauigkeit dargestellt wird, die nach PA, PP und PH für den GP-UKF ein besseres Ergebnis liefert als für den UKF-GAP. Für eine individuelle Gewichtung der einzelnen Kriterien sollten S1, G1, G2 und P1 besonders hervorgehoben werden, da durch diese Anteile das Zeitfenster zur prädiktiven Planung, die Zuverlässigkeit der Prognose und die Sicherheit im Betrieb beschrieben werden, während das Kriterium K1 nur bedingt geeignet ist, um die Qualität der Prognose zu beurteilen. Zur Berücksichtigung dieser Annahmen werden folgende Gewichtungsfaktoren verwendet:

Bewertungskriterium	Gewichtungsfaktor
S1 – PH [λ]	2
G1 – MAPE [%]	2
G2 – FN [%]	2
G3 – FP [%]	1
G4 – PA [λ]	1
P1 – PE [%]	2
P2 – PP [λ]	1
P3 – SSD [%]	1
K1 – LC [λ]	0,5

Tabelle 20: Gewichtungsfaktoren zur Auswertung der Prognosekennzahlen für den Vergleich von GP-UKF und UKF-GAP

Nach (8.15) ergibt sich damit folgendes Gesamtergebnis (gewichtet / ungewichtet):

- GP-UKF: 5,99 / 4,68
- UKF-GAP: 10,61 / 9,02

Damit ermöglicht der GP-UKF sowohl für die gewichtete als auch für die ungewichteten Daten ein im Durchschnitt annähernd doppelt so gutes Ergebnis wie der UKF-GAP.

6.6. Operationelles Potential des GP-UKF Prognosekonzeptes

Für die Potentialanalyse des GP-UKF-Ansatzes wird der Systemaufbruch des in § 3.7.2 beschriebenen Systems (inklusive Boden- und Luftsegment) mit kontinuierlichem Betrieb und der Parametrisierung entsprechend Anhang B verwendet. Für den gegebenen Systementwurf wird bei gleichbleibender FR die Fähigkeit zur Fehlerprognose auf Systemebene von 0% bis auf 90% gesteigert. Die dadurch reduzierten Wartungsaktivitäten und erhöhte SCR werden als Indikator für das operationelle Potential verwendet. Die Auswirkungen auf die PBC-Risikoanalyse sollen weiterhin den wirtschaftlichen Nutzen für serviceorientierte Vertragskonzepte illustrieren.

Durch die Analyse soll im Wesentlichen der gesamte Ablauf zur Potentialanalyse von Prognosealgorithmen dargestellt werden. Ausgehend von der Auswertung der Prognoseeigenschaften durch die Kennzahlen und den Eingabeparametern des MMDL, wird somit eine Möglichkeit zur kombinierten Nutzung des MMDLs und neuer Prognosekonzepte aufgezeigt.

Mittels (7.65) und (7.66) und den gemittelten Prognosekennzahlen des GP-UKF-Ansatzes ergeben sich folgende Größen zur Beschreibung der Prognosegüte:

Relative Genauigkeit der Prognose: $\theta_p = 0,77$

Relative Präzision der Prognose: $\gamma_p = 0,74$

Diese Kennwerte wurden über alle Prognosestartpunkte gemittelt und stellen somit kein eindeutiges Kriterium zur Beschreibung der Prognosequalität des GP-UKF dar, bieten jedoch die Grundlage um eine erste Abschätzung der Auswirkungen auf die operationelle Leistungsfähigkeit vorzunehmen (s. Abbildung 90).

Durch die Berücksichtigung der logistischen Vorlaufzeit als Referenzzeitraum für die relativen Prognosegütemaße lässt sich auch mit den angegebenen Werten von $\gamma_p < \theta_p < 80\%$ eine eindeutige Verbesserung für den Betrieb erreichen. Das Verhältnis zwischen T_L und den jeweiligen Fehlerraten ist zu gering als das hier aufgrund der Prognosekennzahlen eine Verschlechterung der gemittelten Verfügbarkeit zu erwarten wäre. Für den realen Einsatz ist jedoch ausschließlich das Verhältnis zwischen dem Verlust an operationeller Zeit und der benötigten Vorlaufzeit von Interesse, da hierdurch beschrieben wird, wieviel Betriebszeit einer Komponente mit Prognosefähigkeit durch den verfrühten Austausch nicht mehr genutzt werden kann. Bei Vernachlässigung der logistischen Wartezeit durch Erhöhung der FR auf 100% verringert sich entsprechend (5.2) der Zugewinn der Verfügbarkeit auf den Anteil, der durch die reduzierten Wartungsaktivitäten ermöglicht wird, die durch prädiktive Maßnahmen vermiedenen Sekundärfehler und die Automatisierung von Systemchecks (s. § 3.2). Der Wartungsaufwand bleibt davon erwartungsgemäß unbeeinflusst und die Risikoanalyse ergibt für eine FR von 100% bereits für den Systementwurf ohne CBM-Anteil eine Gewährleistung der geforderten SCR.




Abbildung 90: Auswertung des operationellen Potentials des GP-UKF-Ansatzes für das Gesamtsystem mit FR = 75% und FR = 100%: (a), (b) MID, (c), (d) SCR, (e), (f) PBC-Risiko für SCR = 80%

Bei einer Berücksichtigung der inversen Fehlerraten anstelle der logistischen Vorlaufzeiten als Referenzzeitraum für die prädiktive Planung wird das Potential des GP-UKF-Ansatzes entsprechend beeinflusst, indem der Wartungsaufwand erhöht und die erreichbare SCR reduziert wird:




Abbildung 91: Auswertung des operationellen Potentials des GP-UKF-Ansatzes für das Gesamtsystem mit Berücksichtigung der Fehlerraten als Referenzzeitraum und FR = 100%: (a) MID, (b) SCR

Der Zugewinn an Wartungsfreundlichkeit resultiert wiederum aus der verbesserten Fehlerdiagnose und der Vermeidung von Sekundärfehlern durch die prädiktiven Maßnahmen. Bei einer weiteren Reduzierung der Prognosegüte ($\theta_p = \gamma_p = 0,5$) fällt der Zugewinn für die Wartungsfreundlichkeit weiter ab und die erreichbare SCR unter den Wert des ursprünglichen Betreiberkonzeptes:




Abbildung 92: Auswertung des Einflusses der Prognosegüte für das Gesamtsystem mit Berücksichtigung der Fehlerraten als Referenzzeitraum und $FR = 100\%$ für $\theta_p = \gamma_p = 0,5$:
(a) Wartungsaufwand, (b) SCR

Die absoluten Werte basieren auf dem verwendeten Szenario und den getroffenen Annahmen, somit ist die quantitative Aussage nicht als allgemeingültig zu betrachten. Wenn die Optimierung der Fehlersuche durch das COM als Anteil der Prognosefunktion und die Automatisierung von Systemchecks nicht berücksichtigt werden, würde der Grenzwert für die minimal erforderliche Qualität der Prognose deutlich über dem ermittelten Wert liegen, bzw. durch eine nicht perfekte Prognose immer zu einer Reduzierung der Verfügbarkeit führen.

6.7. Zusammenfassung der Ergebnisse

Durch die gewählten Bewertungskriterien lassen sich Kennzahlen herleiten, die alle wesentlichen Eigenschaften von Prognosefunktionen messbar machen. Damit wird eine Bewertung und Vergleichbarkeit unterschiedlicher Ansätze ermöglicht, um die Auswahl und Entwicklung eines geeigneten Konzeptes zu unterstützen.

Für die Verifikation der Prognosefähigkeiten wurden neben den experimentellen Daten auch umfassende Versuche mit synthetischen Degradierungsverläufen unter Berücksichtigung von externen Lasten durchgeführt. Die Konvergenz der Systemidentifikation konnte für alle betrachteten Testfälle bestätigt werden. Der untersuchte GP-UKF-Ansatz ermöglichte für alle Szenarien die Herleitung einer Funktion für eine robuste Fehlerprognose. Die Qualität der Prognose und das Potential des globalen Korrekturfaktors hängen erwartungsgemäß von dem betrachteten Beispiel und der Repräsentativität der Trainingsdaten ab. Bei hinreichender Übereinstimmung zwischen dem Trainings- und Verifikationsdatensatz ermöglicht der Korrekturfaktor eine optimierte Prognose.

Aus den gewonnenen Ergebnissen können folgende Rückschlüsse hinsichtlich einer geeigneten Vorgehensweise zur Parametrisierung der modellbasierten Systemidentifikation gewonnen werden:

- Die geschätzten Kovarianzmatrizen Q_x und R_y sollten nach Abschluss der Systemidentifikation entsprechend den verwendeten Konsistenzkriterien manuell angepasst werden, um eine korrekte Propagierung der statistischen Merkmale der Verteilung $p(CI|u)$ zu gewährleisten. Hierfür ist anschließend die Schätzung der Störgröße ξ_i für alle $i = 1:M$ Modelle zur Bereitstellung einer konsistenten Datenbasis erneut durchzuführen. Während der Systemidentifikation kann durch eine geeignete Gewichtung der entsprechenden Fitnesskriterien (im Wesentlichen F1 und F2) sichergestellt werden, dass die Zustandsschätzung und damit auch die Validierung zuverlässig sind. Auf die gefundenen Modellstrukturen hat dieser Schritt keinen Einfluss und somit bleibt das Ergebnis der Systemidentifikation weiterhin verwendbar.
- Es wurde eine Vorgehensweise abgeleitet, eine optimierte Systemidentifikation zu gewährleisten und ein globales Optimum für die Prognosefunktion zu identifizieren. Hierzu sind statistisch repräsentative Testläufe mit unterschiedlichen Vorgaben für die Anzahl der Individuen und Generationen sowie der Parametrisierung zur Auswahl eines genetischen Operators durchzuführen. Die Zielsetzung sollte sein, den Rechenaufwand zu minimieren und trotzdem ein optimiertes Ergebnis zu erhalten. Die Motivation hierfür resultiert aus der Beobachtung, dass der GP-UKF-Ansatz bereits nach einer verhältnismäßig geringen Anzahl an Generationen auf einem relativ konstanten Fitnessniveau verbleibt, ohne für die gewählten 100 Iterationen in der zweiten Hälfte der Systemidentifikation noch nennenswerte Verbesserungen für die Herleitung der Prognosefunktion aufzuweisen, jedoch trotzdem noch keine über den gesamten Wertebereich optimierte Prognose ermöglicht. Deswegen wird vermutet, dass die *Genetische Programmierung* aufgrund von einer zu geringen Anzahl an potentiellen Lösungen bei einem lokalen Optimum verbleibt und dieses während der durchgeführten Iterationsschritte nicht mehr bedeutend verbessern kann.
- Anhand von Voruntersuchungen konnte ermittelt werden, dass die Vorgehensweise zur Datenklassifikation ebenfalls Auswirkungen auf die erreichbare Qualität und Robustheit der Prognose hat. Das hier genutzte Konzept, mit den Perzentilen der Wahrscheinlichkeitsverteilung des gewählten Klassifikationsparameters als Kriterium zur Aufteilung der Trainingsdatenanteile, bietet nachweislich eine geeignete Methode die hybride Systemidentifikation zu unterstützen. Zur Gewährleistung eines optimalen Ergebnisses sollten jedoch weiterführende Untersuchungen zur problemspezifischen Auswahl von Datenbereichen mittels der gewählten Methode vorgenommen werden.

Durch die Variation der Relevanz der äußeren Lasten für den Degradierungsverlauf der synthetischen Daten wurde nachgewiesen, dass die modellbasierte Systemidentifikation nicht nur ein über alle Trainingsdaten optimiertes Modell identifizieren kann, sondern auch die Sensitivität gegenüber Eingangsgrößen berücksichtigt.

Anhand der experimentellen Testreihen konnte gezeigt werden, dass der GP-UKF-Ansatz in der Lage ist, bei eindeutigen Trainingsdaten beliebige Verläufe exakt wieder zu geben. Bei einer Erweiterung der Trainingsdaten verliert sich diese Fähigkeit, da der hybride Prognoseansatz versucht den mittleren Fehler über alle Verläufe zu minimieren. Eine Weiterführung der beschriebenen Arbeiten könnte somit darin bestehen, den Wiedererkennungswert von bereits bekannten Verläufen durch entsprechende Maßnahmen bei der Bestimmung der Modellgewichtungen und Rekonstruktion der geschätzten Datenmodule zu erhöhen. Die Propagierung von Unsicherheiten konnte durch die gewählte Vorgehensweise zuverlässig und ohne eine Divergenz der betrachteten Verläufe gewährleistet werden. Dennoch ist besonders bei Verläufen mit hohem SNR nicht sichergestellt, dass alle Teilverläufe innerhalb der propagierten Vertrauensbereiche liegen. Somit besteht der Bedarf, den Anteil des GP-UKF-Ansatzes, der für die Aufbereitung und Propagierung der Unsicherheiten zuständig ist, weitergehend zu prüfen und gegebenenfalls Optimierungen vorzunehmen. Die vielfältige Anwendbarkeit des GP-UKF-Ansatzes konnte dadurch nachgewiesen werden, dass die Parametrisierung der Systemidentifikation und der Prognose für alle Testfälle identisch war und trotzdem individuelle Lösungen ermöglicht hat. Im Vergleich mit dem UKF-GAP aus [52] hat der GP-UKF-Ansatz für alle betrachteten Szenarien ein besseres Ergebnis geliefert und ermöglicht eine im Durchschnitt deutlich robustere und zuverlässigere Prognosefähigkeit.

Aus den Ergebnissen der Potentialanalyse mittels des MMDL lässt sich schließen, dass die Qualität der Prognose erwartungsgemäß einen maßgeblichen Einfluss auf das operative Potential von Zustandsüberwachungssystemen zur Unterstützung von prädiktiven Instandhaltungskonzepten hat. In Abhängigkeit von der Prognosegüte und dem Verhältnis zwischen dem Prognosehorizont und den Vorlaufzeiten zur prädiktiven Planung kann der Wartungsaufwand trotz der Vermeidung von Sekundärfehlern erhöht und die erreichbare SCR reduziert werden.

7. Zusammenfassung und Ausblick

In diesem Abschnitt werden die Arbeitsschritte zum Erreichen der Ziele für die Potentialanalyse für Diagnose & Prognose und das untersuchte Prognosekonzept zusammengefasst und die Ergebnisse abschließend diskutiert. Ausgehend von den getroffenen Annahmen, Erkenntnissen während der Umsetzung und dem Vergleich mit existierenden Ansätzen, werden anschließend die gesammelten Ideen für weiterführende Arbeiten erläutert.

7.1. Inhalt und Ergebnisse der Arbeit

Der Einsatz von Diagnose- und Prognosefunktionen bietet vielversprechende Möglichkeiten die Verfügbarkeit von Luftfahrtsystemen zu erhöhen und gleichzeitig zu einer verbesserten Zuverlässigkeit bei der Erfüllung von Missionsszenarien beizutragen. Mit dieser These wird eine Grundlage geschaffen, um Investitionen in das dafür erforderliche Systemdesign und Betreiberszenario zu rechtfertigen. Die Forschungsarbeiten in diesem Bereich konnten bisher keine befriedigende Antwort liefern, welches operationelle Potential eine Zustandsüberwachung mit Fähigkeiten zur Fehlerprognose letztendlich bieten kann. Um das Verständnis in diesem Bereich zu erweitern, ist eine entsprechende Simulationsumgebung aufgebaut worden. Bei der Modellbildung wurden die hierfür wesentlichen Aspekte aus den Bereichen der Zustandsüberwachung, Zuverlässigkeitsanalyse, Instandhaltung und Logistik berücksichtigt, um für einen gegebenen Systementwurf eine mathematisch geschlossene Lösung zur Bestimmung der theoretisch erreichbaren Verfügbarkeit herzuleiten. Durch eine Erweiterung des deterministischen Modells um die Berücksichtigung der ersten beiden statistischen Momente ausgewählter Größen, war neben der Bestimmung der Erwartungswerte aller Ausgabegrößen auch eine Analyse der Auswirkungen von Unsicherheiten im Systemdesign und Betreiberkonzept auf die resultierende Verteilung des Wartungsaufwandes und der Systemverfügbarkeit möglich. Die Gültigkeit des Modells wurde mittels einer zertifizierten Anwendung anhand diverser Parameteranalysen erfolgreich nachgewiesen. Das hierfür verwendete Szenario nähert eine repräsentative Systemauslegung von Luftfahrtsystemen an und berücksichtigt sowohl Boden- als auch Luftsegmente.

Die Potentialanalyse von Diagnose und Prognose ermöglichte den Vergleich zwischen verschiedenen Betreiber- und Instandhaltungskonzepten. Unabhängig von der Tatsache, dass sowohl aufgrund von rein technischen, als auch zulassungsrelevanten und ökonomischen Gründen die Bereitstellung von Diagnosefunktionen mit Prognosefähigkeit für fliegende Systeme einen sehr begrenzten Einsatzbereich bietet, konnte der operationelle Vorteil von prädiktiven Wartungsmaßnahmen anschaulich nachgewiesen werden. Während eine verbesserte Diagnose zur Unterstützung von präventiver Instandhaltung im Wesentlichen den Wartungsaufwand und Bedarf an Ersatzteilen reduzieren kann, bietet eine Prognosefähigkeit darüber hinaus auch eine Unabhängigkeit von Lieferantenzeiten und

Unsicherheiten in der erwarteten Fehlerrate von Einzelkomponenten. Somit wird durch eine integrierte Prognosefunktion und ein dadurch unterstütztes Instandhaltungs- und Logistikkonzept nicht nur die erreichbare Verfügbarkeit deutlich erhöht, sondern auch die Wahrscheinlichkeit zur erfolgreichen Gewährleistung eines angestrebten Wertes, was einer Reduzierung des operationellen Risikos für leistungsbasierte Vertragskonzepte entspricht.

Das vorgestellte Simulationsmodell bietet durch die beschriebene Analysefähigkeit eine Plattform zur Validierung & Verifikation von Anforderungen aus dem Bereich der Zuverlässigkeitsanalyse und Integration eines Zustandsüberwachungssystems. Die hierfür erforderliche Vorgehensweise wurde in der Arbeit nicht detailliert diskutiert, bedarf jedoch durch den hierarchischen Aufbau des Modells keiner weiteren Modellanpassung. Des Weiteren liefert die beschriebene Analyse der Unsicherheiten von Modellausgabewerten eine fundierte Grundlage, um unabhängig von der Art der Systemauslegung und Instandhaltungsstrategie die Risikoanalyse für leistungsorientierte Vertragskonzepte zu unterstützen.

Die *Genetische Programmierung* bietet vielseitig einsetzbare Möglichkeiten zur Systemidentifikation und liefert als Ausgabe eine mathematische oder logische Beschreibung des betrachteten Systems. Diese Fähigkeit wurde erfolgreich genutzt, um die Herleitung von Modellen für beliebige Degradierungsprozesse zu unterstützen. Die gewählte Implementierungsform der *Genetischen Programmierung* nutzt einen *Multi-Gene Regression*-Ansatz, wodurch ein beobachtetes Eingangs- und Ausgangsverhältnis mittels mehrerer Teilmodelle beschrieben wird. In den bisher bekannten Anwendungen werden diese Modelle jeweils für den gesamten Datenbereich genutzt, wobei die jeweilige Relevanz durch individuelle Gewichtungsfaktoren empirisch bestimmt wird. Dieses Konzept wurde erweitert, um durch eine vorausgehende Klassifikation der Trainingsdaten für jedes verwendete Teilmodell einen Gültigkeitsbereich festzulegen und somit eine „*Multiple-Model Systemidentifikation*“ zu ermöglichen. Das Konzept der *Multi-Gene Regression* wird dabei unverändert angewendet, jedoch ist während der Systemidentifikation jeweils nur ein Modell aktiv, wodurch die Optimierung dieses Teilmodells für den betrachteten Datenbereich ermöglicht wird. Die Fähigkeit zur Herleitung eines *Multiple-Model*-Ansatzes ohne Vorkenntnisse über die benötigte Modellstruktur konnte für ausgewählte Beispiele erfolgreich nachgewiesen werden.

Unter Kenntnis der Modellstruktur im Zustandsraum eignen sich rekursive bayessche Schätzverfahren für die Störgrößenkompensation (Signalaufbereitung), Schätzung von unbekannten Modellgrößen (Parameter und Zustände) und der Propagierung der ersten beiden statistischen Momenten kontinuierlich verteilter Zufallszahlen. Das *Unscented Kalman Filter* bietet die Möglichkeit, mit einem minimierten Rechenaufwand und hinreichender Stabilität sowohl lineare als auch nichtlineare Schätzprobleme handzuhaben. Dadurch motiviert ist das UKF für die Implementierung der modellbasierten Systemidentifikation als eigenständiges Modul in die *Genetische Programmierung* inte-

griert worden. Durch die Nutzung des UKFs als integraler Bestandteil der Systemidentifikation konnte neben der Modellbildung für messbare Eingangs- und Ausgangsgrößen auch eine Zustandsschätzung von unbekannten Modellgrößen ohne vorherige Kenntnis der Modellstruktur ermöglicht werden. Die Schätzung von unbekannten Störgrößen erfolgt für das Schadensmodell anhand eines zeitvarianten Zustandes ohne explizites Prozessmodell, während die Bestimmung der zu prognostizierenden Schadensgröße und zugehörigen statistischen Eigenschaften durch eine Zustandsschätzung im üblichen Sinne realisiert wird. Die geschätzten Störgrößen bieten aufgrund der Freiheitsgrade während der Systemidentifikation ohne Vorgabe von Gültigkeitsbereichen keine Grundlage zur Rekonstruktion von physikalischen Größen, was jedoch keine Einschränkungen für die Implementierung als Prognosefunktion bedeutet. Für diese erweiterte Schätzaufgabe zur Bestimmung von Zuständen mit und ohne explizitem Prozessmodell sind die verschiedenen Implementierungsformen des UKFs getestet und miteinander verglichen worden, um die hinsichtlich Zuverlässigkeit und Rechenaufwand optimalste Lösung zu verwenden. Zur Unterstützung der modellbasierten Systemidentifikation sind zusätzlich zur gängigen Strategie für die *Genetische Programmierung* ausgewählte Kriterien aus dem Bereich der Konsistenzbewertung von adaptiven Filtern hergeleitet, implementiert und validiert worden.

Für die Realisierung eines hybriden Prognoseansatzes werden der Prognosefunktion die identifizierte Modellstruktur und ausgewählte Datensätze aus der Systemidentifikationsphase zur Verfügung gestellt. Die gewählten Datensätze bilden die Korrelation zwischen den Eingangsgrößen und den identifizierten Modellgleichungen und geschätzten Störgrößen ab, wodurch für die Prognosephase auch ohne Kenntnis des realen Verlaufes der Schadensgröße durch die Vorgabe zukünftiger Nutzungsprofile eine Modellauswahl und Propagierung der statistischen Eigenschaften der geschätzten Störgrößen möglich ist. Hierfür wurde das UKF modifiziert, um eine Prognosefähigkeit ohne verfügbare Messwerte zu ermöglichen. Der *Interacting Multiple Model*-Ansatz aus dem Bereich der hybriden Filterung wurde verwendet, um die *Multiple-Model Systemidentifikation* auch für die Prognosephase zu implementieren. Für die Bereitstellung der modellspezifischen Eigenschaften der geschätzten Störgrößen ist ein entsprechendes Verfahren vorgestellt worden, das durch die Berücksichtigung der Zeitpunkte des Auftretens für jeden individuellen Trainingsanteil eine statistisch repräsentative Nachbildung des Wissens aus der Systemidentifikation ermöglicht und dem UKF für jeden Prädiktionsschritt zur Verfügung stellt. Die Herleitung und Implementierung der hybriden Prognose, mit einem datenbasierten und modellbasierten Anteil, konnte für ein ausgewähltes Beispiel anhand der korrekten Propagierung der ersten beiden statistischen Momente eines stochastischen Merkmals erfolgreich nachgewiesen werden. Weitergehend wurde Bayes Theorem für bedingte Wahrscheinlichkeiten genutzt, um aus den empirisch ermittelten Informationen die Auswahl der Teilmodelle für den *Interacting Multiple Model*-Ansatz in Abhängigkeit von der Sensitivität des

gewählten Merkmals zur Modellauswahl gegenüber den verfügbaren Eingangsgrößen zu unterstützen.

Die modellbasierte Systemidentifikation konnte durch den Prognoseanteil um eine Bewertungsgrundlage für die Herleitung von Degradierungsmodellen erweitert werden. Die Trainingsphase der Modellidentifikation besteht hierbei weiterhin aus dem modellbasierten Anteil mit Zustandsschätzung. Die Validierungsphase der Systemidentifikation wird durch die Prognosefunktion unterstützt, wofür entsprechende Bewertungskriterien aufgestellt und in der Modellbewertung berücksichtigt worden sind. Durch den modularen Aufbau mit daten- und modellbasierten Anteilen wird die automatische Entwicklung einer hybriden Fehlerprognose zielgerichtet unterstützt. Die Konvergenz der *Genetischen Programmierung* wurde für ausgewählte Beispiele nachgewiesen. Basierend auf vorhergehenden Arbeiten ist zusätzlich ein empirisches Verfahren zur Steigerung der Prognosequalität weiter entwickelt und in den GP-UKF integriert worden.

Zum Nachweis der Allgemeingültigkeit und Leistungsfähigkeit des untersuchten GP-UKF-Ansatzes sind parametrische Ansätze zur Simulation von Degradierungsverläufen unter Berücksichtigung von messbaren und nicht messbaren Einflussgrößen aufgestellt worden. Der GP-UKF ermöglicht für alle betrachteten Testszenarien eine robuste Fehlerprognose, deren Qualität im Wesentlichen durch die Eignung der Testdaten bestimmt wird. Auch für experimentelle Daten, die mit einem speziell präparierten luftfahrttauglichen Lüfter gesammelt wurden, konnte die Prognosefähigkeit trotz einer sehr großen Variabilität in den Trainingsdaten erfolgreich nachgewiesen werden. Die Eignung des empirischen Ansatzes zur Verbesserung der Prognosegüte wurde allgemeingültig für alle betrachteten Szenarien gezeigt. Um die Qualität der Fehlerprognose auch quantitativ und möglichst umfassend bewerten zu können, sind entsprechende Bewertungskriterien sowohl der Literatur entnommen als auch selbst aufgestellt und implementiert worden.

Im Vergleich mit dem aktuellen Stand der Technik aus dem Bereich der hybriden Fehlerprognose lieferte der untersuchte GP-UKF-Ansatz ein deutlich besseres Ergebnis als eine Kombination aus Gauß-Prozess, UKF und IMM, womit das Ergebnis der Verifikation auch objektiv betrachtet die Eignung des GP-UKF zur Bereitstellung und Anwendung eines hybriden Fehlerprognoseansatzes erfolgreich nachweist.

Durch die Herleitung entsprechender mathematischer Zusammenhänge konnten die Ergebnisse der Verifikation genutzt werden, um die erreichte Qualität der Prognose als Vorgabegröße für den aufgestellten Modellansatz zur operationellen Potentialanalyse von Diagnose und Prognose zu verwenden. Diese abschließende Analyse weist die Eignung des GP-UKF-Ansatzes für den betrachteten Testfall nach und kann darüber hinaus den Beweis erbringen, dass in Abhängigkeit von dem betrachteten operationellen Szenario ein Mindestmaß an Prognosequalität erforderlich ist, um die

Wartungsaufwände nicht zu erhöhen und dadurch letztendlich auch die erreichbare Verfügbarkeit zu reduzieren.

Insgesamt stellt die vorliegende Arbeit neue Methoden zur Bewertung des operationellen Nutzens von Diagnose- und Prognosefunktionen sowie zur Fehlerprognose ohne vorherige Kenntnisse über das zu prognostizierende System vor. Darauf aufbauend wird die Möglichkeit beschrieben, eine nachgewiesene Prognosegüte hinsichtlich des operationellen Nutzens zu bewerten. Damit werden einige wesentliche Elemente, die zur Entwicklung und Zertifizierung von prädiktiven Instandhaltungskonzepten benötigt werden, hergeleitet, erfolgreich implementiert und in Relation zu luftfahrt-technischen Anwendungen diskutiert.

7.2. Weiterführende Arbeiten

Die Möglichkeiten zur Weiterentwicklung der Ergebnisse dieser Arbeit können entsprechend des inhaltlichen Aufbaus in zwei Bereiche aufgeteilt werden:

- 1) Erweiterungen der Simulationsumgebung zur operativen Potentialanalyse.
- 2) Verbesserung des GP-UKF-Ansatzes zur Systemidentifikation und Fehlerprognose.

Die während der Arbeit entwickelten Ideen zur Erweiterung, bzw. Optimierung der beiden Ansätze werden im Folgenden für die beiden Anteile MMDL und GP-UKF konzeptspezifisch und allgemeingültig dargestellt.

7.2.1. Weiterentwicklung des Maintenance Modells

Für das MMDL besteht ein Potential zur Optimierung der Simulationsfähigkeit in der Implementierung von möglichst exakten Annäherungen der Verteilungsformen anstelle der Nutzung von Mittelwerten und Varianzen um die statistischen Eigenschaften der Modellparameter zu beschreiben. Hiermit wäre die zuverlässige Berücksichtigung von höheren statistischen Momenten wie der Schiefe oder Wölbung der Eingabe- und Ausgabeparameter gewährleistet.

Wie die Ergebnisse der Modellvalidierung gezeigt haben, ist die Aussagekraft des MMDL beschränkt, wenn die Anzahl der operativen Systeme und Komplexität des betrachteten Szenarios zunimmt. Zum Abgleich der resultierenden Verteilungen wäre es somit sinnvoll, ähnlich wie bei der genutzten Systecon-Umgebung, die Konfiguration und Teilergebnisse des MMDL als Eingabeparameter für eine Monte-Carlo Simulation zu verwenden, um somit auch komplexere operationelle Szenarien zuverlässig abbilden zu können.

7.2.2. Optimierung des GP-UKF-Ansatzes

Im Rahmen dieser Arbeit wurde eine gängige Form der *Genetischen Programmierung* genutzt und entsprechend angepasst, um die modellbasierte Systemidentifikation und hybride Fehlerprognose zu

ermöglichen. Es gibt neben der verwendeten Implementierung jedoch noch vielfältige andere Varianten, die entwickelt wurden, um die Rechenzeit zu reduzieren, bzw. das Ergebnis zu verbessern [55], [76], [128]. Da die *Genetische Programmierung* einen wesentlichen Beitrag zur Herleitung geeigneter Modell liefert, sollte dieser Anteil und das damit verbundene Optimierungspotential weitergehend analysiert werden.

Unabhängig von der gewählten Form der *Genetischen Programmierung* hat sich während der Arbeit herausgestellt, dass die Qualität der Prognose von der Wahl und der unterschiedlichen Gewichtung der einzelnen Bewertungskriterien für die Systemidentifikation abhängt. Um die Herleitung der Modelle optimal zu unterstützen, sollte die Vorgehensweise zur Auswahl der Kriterien und deren einzelne Gewichtungen weitergehend betrachtet werden. Die Zielsetzung hierbei sollte sein, eine möglichst geringe Anzahl an Kriterien zu verwenden, die eine hohe Aussagekraft über die Qualität der hergeleiteten Datenmodule und die Eignung der Modelle für die Fehlerprognose besitzen.

Bei Verwendung einer analytisch geschlossenen Lösung für die Prognose mittels des UKFs oder anderer Verfahren zur Propagierung der statistischen Eigenschaften des CI bleibt zu berücksichtigen, dass der gewählte Ansatz zur Prädiktion der zeitvarianten Störgröße ξ nur eine Annäherung der statistischen Momente ermöglicht. Da die resultierenden Verteilungen $p(CI_k|u_k, CI_{k-1})$ und $p(EoP|CI)$ maßgeblich durch ξ mitbestimmt werden, sollten zur Optimierung der Prognoseergebnisse hinsichtlich Genauigkeit, Präzision und Gewährleistung der Verfügbarkeit und Sicherheit im Betrieb alternative Ansätze zur Prädiktion des Erwartungswertes und der Varianz von ξ untersucht werden.

Falls die Implementierung einer mathematisch geschlossenen Lösung für den Prognoseanteil keine feste Forderung für die Entwicklung ist, kann auch eine Form der Monte-Carlo Simulation genutzt werden, um über eine hinreichend große Anzahl an Einzeltrajektorien mit zufällig erzeugten Anteilen des Datensatzes ξ einen repräsentativen Verlauf der Verteilung $p(CI_k|u_k, CI_{k-1})$ zu ermöglichen. Hiermit wäre zwar ein erhöhter Rechenaufwand verbunden, jedoch sichergestellt, dass die resultierende Verteilung $p(EoP|CI)$, unter Vernachlässigung des Einflusses der Qualität der Modellidentifikation, alle statistischen Eigenschaften der genutzten Trainingsdaten korrekt abbildet.

Allgemeingültig können ebenfalls andere Formen zur rekursiven Filterung wie z.B. Partikelfilter hinsichtlich ihrer Eignung zur Kompensation von Messungenauigkeiten und zur Bestimmung der Datenmodule untersucht werden, ohne dabei die anderen Anteile des Prognosekonzeptes zu modifizieren.

Die Propagierung der statistischen Eigenschaften von Betriebs- und Umgebungsbedingungen ist allgemein ein wichtiger Bestandteil von Prognosefunktionen. Im Rahmen dieser Arbeit wurde dieser Anteil vernachlässigt, indem die Betriebsbedingungen als bekannt vorausgesetzt, bzw. ohne

Berücksichtigung von Unsicherheiten extrapoliert wurden. In Abhängigkeit von der Anzahl der berücksichtigten Nutzungsbedingungen und deren Relevanz für den Verlauf des CI, ist der Einfluss von Unsicherheiten für die zukünftige Nutzung nicht zu vernachlässigen und geeignete Verfahren zur Berücksichtigung bei der Bestimmung der Verteilungen $p(CI_k|u_k, CI_{k-1})$ und $p(EoP|CI)$ sollten aufgestellt und validiert werden.

Für die Entwicklung der Fähigkeit zur hybriden Fehlerprognose sind alle verfügbaren Trainingsdaten entsprechend dem gewählten Ansatz zur Datenklassifikation in unterschiedliche Anteile aufgeteilt worden, um hierfür ausgehend von der *Multi-Gene Regression* der *Genetischen Programmierung* jeweils ein Teilmodell herzuleiten. Eine alternative Variante, die auch eine bessere Berücksichtigung von bereits bekannten Verläufen ermöglichen würde, bietet die Herleitung von jeweils einem Teilmodell für jede Einzeltrajektorie des Trainingsdatensatzes. Hiermit würde zwar die Anzahl der benötigten Modelle mit der Anzahl der Trainingsdatensätze linear zunehmen, jedoch würde durch diesen Ansatz die Wiederverwendbarkeit von vorhandenem Wissen individueller unterstützt werden, indem das Ergebnis der Systemidentifikation nicht den mittleren Fehler über alle Modelle minimiert, sondern jeweils zwischen dem zu prognostizierenden Teilverlauf und den am besten geeigneten Einzeltrajektorien aus dem Trainingsdatensatz.

Wie für alle datenbasierten Verfahren aus beliebigen Anwendungsfeldern ist auch für den untersuchten GP-UKF-Ansatz die Klassifikation der Trainingsdaten von entscheidender Bedeutung für die Qualität der erzielten Lösung. In der hier vorliegenden Arbeit wurde die Auswahl von synthetischen Datensätzen für die Systemidentifikation, Validierung und Verifikation zufällig vorgenommen, da die Datenbasis der synthetischen Trainingsdaten als hinreichend umfassend angenommen wurde. Prinzipiell sollte jedoch auch für die Fehlerprognose ein Konzept entwickelt werden, das eine vergleichbare Informationsbasis für die Trainings- und Testphase schafft. Hierfür sollten geeignete Verfahren zur Klassifikation der vorliegenden Daten während der Entwicklungs- und Nutzungsphase entwickelt und anhand des Einflusses auf die Qualität der Prognoseergebnisse getestet und bewertet werden.

Referenzen

- [1] Geary, S., Vitasek, K., „*Performance-Based Logistics: A Contractor's Guide to Life Cycle Product Support Management*”, Supply Chain Visions, 2008
- [2] Lee, S.G., Ma, Y.-S., Thimm, G.L., Verstraeten, J., „*Product lifecycle management in aviation maintenance, repair and overhaul*”, Journal of Computers in Industry 2008, Vol. 59, pp. 296-303
- [3] Edwards, T., „*Liquid Fuels and Propellants for Aerospace Propulsion: 1903–2003*”, Journal of Propulsion and Power 2003, Vol. 19
- [4] Byer, B., Hess, A., Fila, L., „*Writing A Convincing Cost Benefit Analysis to Substantiate Autonomic Logistics*”, IEEE Aerospace Conference Proceedings 2001, Vol. 6, pp. 3095-3103
- [5] Reimann, J., Kacprzynski, G., Cabral, D., Marim, R., „*Using Condition Based Maintenance to Improve the Profitability of Performance Based Logistic Contracts*”, Annual Conference of the Prognostics and Health Management Society 2009
- [6] Jazouli, T., Sandborn, P., „*Using PHM to Meet Availability-Based Contracting Requirements*”, IEEE Conference on Prognostics and Health Management 2011
- [7] Wilmering, T.J., Ramesh, A.V., „*Assessing the Impact of Health Management Approaches on System Total Cost of Ownership*”, IEEE Aerospace Conference Proceedings 2005, pp. 3910-3920
- [8] Defence Acquisition University Supply Chain Visions, „*Case Study: The Application of Performance-Based Logistics and Public Private Partnering to Improve Readiness in Naval Aviation (NAVAIR's) Auxiliary Power Unit Total Logistics Support Program*”, 2008
- [9] Willcox, K., „*Aircraft Systems Engineering Cost Analysis*”, MIT Aerospace Computational Design Laboratory, 2002
- [10] Cadick, J., Traugott, G., „*Condition Based Maintenance - A White Paper Review of CBM Analysis Techniques*”, Cadick Corporation, Technical Bulletin 2009
- [11] Reimann, J., Kacprzynski, G., Cabral, D., Marini, R., „*Using Condition Based Maintenance to Improve the Profitability of Performance Based Logistic Contracts*”, Annual Conference of the Prognostics and Health Management Society 2009
- [12] F-35 LRIP I PBA, „*F-35 Joint Strike Fighter Program LRIP I Performance based Agreement (PBA) between the Joint Strike Fighter Program Office (JSFPO) and the United States Air Force (USAF)*”, 2005
- [13] MIL-STD 2173D, „*Reliability - Centered Maintenance Requirements for Naval Aircraft, Weapons Systems and Support Equipment*”, United States Department of Defense, 1981
- [14] Reiss, D., „*Amplification of the Benefits of a Reliable and Maintainable Design by Adequate Maintenance and Support Concepts*”, Daimler Chrysler Aerospace AG München, Military Aircraft Division Defense Technical Information Center, 2000
- [15] Raju, V.R.S., Gandhi, O.P., Deshmukh, S.G., „*Maximizing Operational Availability of Aircraft by Enhancing D Level Maintenance Efficiency*”, International Journal of Advanced Engineering & Application 2011
- [16] Orsagh, R.F., Sheldon, J., „*Prognostics / Diagnostics for Gas Turbine Engine Bearings*”, IEEE Aerospace Conference Proceedings 2003, Vol. 7, pp. 3095-3103

- [17] Zhisheng, C., Lin, M., Rui, L., Yingying, G. and Lei, L., „*Combine RCM and PHM to Impact on Logistics System*”, IEEE Conference on Prognostics and System Health Management 2011
- [18] Bain, K.T., Orwig, D.G., „*F/A-18E/F Built-in-test (BIT) Maturation Process*”, National Defense Industrial Association, Systems Engineering Committee, 3rd Annual systems Engineering & Supportability Conference 2000
- [19] Carrasco, M., Cassady, C.R., „*A Study of the Impact of Prognostic Errors on System Performance*”, Annual Reliability and Maintainability Symposium 2006
- [20] Unger, E.J., „*An Examination of the Relationship between Usage and Operating and Support Costs for Air Force Aircraft*”, RAND Corporation, 2007
- [21] International Air Transport Association Maintenance Cost Task Force, „*Airline Maintenance Cost Executive Commentary*”, 2011
- [22] Niu, G., Pecht, M., „*A Framework for Cost-effective and Accurate Maintenance Combining CBM, RCM and Data Fusion*”, International Conference on Reliability, Maintainability and Safety 2009
- [23] DIN EN 13306:2010-12, „*Instandhaltung - Begriffe der Instandhaltung*”, Deutsches Institut für Normung, 2010
- [24] MIL-STD-1629A, „*Procedures for Performing a Failure Mode, Effects and Criticality Analysis*”, United States Department of Defense, 1980
- [25] MIL-STD-2165, „*Testability Program for Electronic Systems and Equipments*”, United States Department of Defense, 1985
- [26] S9081-AB-GIB-010, „*Reliability-Centered Maintenance (RCM) Handbook*”, Naval Sea System Command, 2007
- [27] Larder, B.D., Davis, M.W., „*HUMS Condition Based Maintenance Credit Validation*”, 63rd Annual Forum of the American Helicopter Society 2007
- [28] Buderath, M., Adhikari, P.P., „*Simulation Framework and Certification Guidance for Condition Monitoring and Prognostic Health Management*”, European Conference of the Prognostics and Health Management Society 2012
- [29] Schwabacher, M.A., „*A Survey of Data-Driven Prognostics*”, Proceedings of the AIAA Aerospace Conference 2005
- [30] Medjaher, K., Zerhouni, N., Baklouti, J., „*Data-Driven Prognostics Based on Health Indicator Construction: Application to PRONOSTIA's Data*”, European Control Conference 2013, pp. 1451-1456
- [31] Goebel, K., Saha, B., Saxena, A., „*A Comparison of three Data-Driven Techniques for Prognostics*”, NASA Ames Research Center 2008
- [32] Dawn, A., Kim, N.H., Choi, J.H., „*Options for Prognostics Methods: A review of data-driven and physics-based prognostics*“, AIAA Conference of Structural Dynamics and Materials 2013, pp. 7185-7203
- [33] Uckun, S., Goebel, K., Lucas, P.J.F., „*Standardizing Research Methods for Prognostics*”, International Conference on Prognostics and Health Management 2008

- [34] Jaloretto, M.R., Bizarria, C., Galvao, R., „*Trend Analysis for Prognostics and Health Monitoring*”, Brazilian Symposium on Aerospace Engineering & Applications 2009
- [35] Groer, P.G., „*Analyses of Time-To-Failure with a Weibull Model*”, Proceedings of the Maintenance and Reliability Conference 2000, Vol. 59, pp. 1-4
- [36] Maio, F.D., Zio, E., „*A Data-Driven Fuzzy Approach for Predicting the Remaining Useful Life in Dynamic Failure Scenarios of a Nuclear System*”, Reliability Engineering & System Safety 2010, Vol. 95, pp. 49-57
- [37] Pandian, A., Ali, A., „*A Review of Recent Trends in Machine Diagnosis and Prognosis Algorithms*”, World Congress on Nature & Biologically Inspired Computing 2009, pp. 1731-1736
- [38] Gebraeel, N.Z., Lawley, M.A., „*A Neural Network Degradation Model for Computing and Updating Residual Life Distributions*”, IEEE Transactions on Automation Science and Engineering 2008, Vol. 5, pp. 154-163
- [39] Rao, B.K.N., Srinivasa, Pai, P., Nagabhushana, T.N., „*Failure Diagnosis and Prognosis of Rolling - Element Bearings using Artificial Neural Networks: A Critical Overview*”, Journal of Physics Conference Series 2012, Vol. 364
- [40] Khawaja, T., Vachtsevanos, G., „*A novel Architecture for on-line Failure Prognosis using Probabilistic Least Squares Support Vector Regression Machines*”, Annual Conference of the Prognostics and Health Management Society 2009
- [41] Javed, K., Gouriveau, R., Zemouri, R., Zerhouni, N., „*Improving Data-Driven Prognostics by Assessing Predictability of Features*”, Annual Conference of the Prognostics and Health Management Society 2011
- [42] Liu, D., Pang, J., Zhou, J., Peng, Y., Pecht, M., „*Prognostics for State of Health Estimation of Lithium-Ion Batteries based on Combination Gaussian Process Functional Regression*”, Microelectronics Reliability 2013, Vol. 53, pp. 832-839
- [43] Wang, Y., Wang, W., „*Failure Prognostic of Systems with Hidden Degradation Process*”, Journal of Systems Engineering and Electronics 2012, Vol. 23, pp. 314-324
- [44] Daigle, M., Saha, B., Goebel, K., „*A Comparison of Filter-based Approaches for Model-based Prognostics*”, IEEE Aerospace Conference Proceedings 2012, pp. 1-10
- [45] Celaya, J.R., Kulkarni, C., Biswas, G., Saha, S., Goebel, K., „*A Model-based Prognostics Methodology for Electrolytic Capacitors Based on Electrical Overstress Accelerated Aging*”, Annual Conference of the Prognostics and Health Management Society 2011
- [46] Bechhoefer, E., „*A Method for Generalized Prognostics of a Component Using Paris Law*”, 64th Annual Forum of the American Helicopter Society 2008
- [47] Zhang, X., Pisu, P., „*An Unscented Kalman Filter Based Approach for the Health-Monitoring and Prognostics of a Polymer Electrolyte Membrane Fuel Cell*”, Annual Conference of the Prognostics and Health Management Society 2012
- [48] Zhu, J., Yoon, J.M., He, D., Qu, Y., Bechhoefer, E., „*Lubrication Oil Condition Monitoring and Remaining Useful Life Prediction with Particle Filtering*”, International Journal of Prognostics and Health Management Society 2013, Vol. 4
- [49] Chen, H., „*A Multiple Model Prediction Algorithm for CNC Machine Wear PHM*”, International Journal of Prognostics and Health Management Society 2011, Vol. 2

- [50] Brotherton, T., „*Prognosis of Faults in Gas Turbine Engines*”, IEEE Aerospace Conference Proceedings 2000, Vol. 6, pp. 163-171
- [51] Liu, D., Guo, L., Pang, J., Peng, Y., „*A Fusion Framework with Nonlinear Degradation Improvement for Remaining Useful Life Estimation of Lithium-ion Batteries*”, Annual Conference of the Prognostics and Health Management Society 2013
- [52] Anger, C., Schrader, R., Klingauf, U., „*Unscented Kalman Filter with Gaussian Process Degradation Model for Bearing Fault Prognosis*”, European Conference of the Prognostics and Health Management Society 2012
- [53] Mohanty, S., Teale, R., Chattopadhyay, A., Peralta, P., Willhauck, C., „*Mixed Gaussian Process and State-Space Approach for Fatigue Crack Growth Prediction*”, International Workshop on Structural Health Monitoring 2007
- [54] Xu, J., Xu, L., „*Health management based on fusion prognostics for avionics systems*”, Journal of Systems Engineering and Electronics 2011, Vol. 22, pp. 428-436
- [55] Qian, L., Wang, H., Dougherty, E.R., „*Inference of Noisy Nonlinear Differential Equation Models for Gene Regulatory Networks Using Genetic Programming and Kalman Filtering*”, IEEE Transactions on Signal Processing 2008, Vol. 56, pp. 3327-3339
- [56] Tao, Y., Cao, J., „*Dynamic Population Variation Genetic Programming with Kalman Operator for Power System Load Modeling*”, Proceedings of the 17th International Conference on Neural Information Processing: Theory and Algorithms 2010, Vol. 1, pp. 520-531
- [57] Nasser, M., Moeini, A., Tabesh, M., „*Forecasting monthly urban water demand using Extended Kalman Filter and Genetic Programming*”, International Journal of Expert Systems with Applications 2011, Vol. 38, pp. 7387-7395
- [58] DIN EN 60812:2006-11, „*Analysetechniken für die Funktionsfähigkeit von Systemen - Verfahren für die Fehlzustandsart- und -auswirkungsanalyse (FMEA)*”, Deutsches Institut für Normung, 2006
- [59] SAE ARP 5580, „*Recommended Failure Modes and Effects Analysis (FMEA) Practices for Non-Automobile Applications*”, SAE G-11 Committee, 2001
- [60] Alabdulkarim, A.A., Ball, P.D., Tiwari, A., „*Applications of simulation in maintenance research*”, World Journal of Modelling and Simulation 2013, Vol. 9, pp. 14-37
- [61] Rausand, M., Hoyland, A., „*System Reliability Theory: Models, Statistical Methods and Applications*”, John Wiley & Sons, 2004
- [62] Upadhyay, K.S., Srinivasan, N.K., „*Availability of Weapon Systems with Logistic Delays: A Simulation Approach*”, International Journal of Reliability, Quality and Safety Engineering 2003, Vol. 10, pp. 429-444
- [63] Harkins, W., „*Mean Time To Repair Predictions*”, NASA TM 4628A, Recommended Techniques for Effective Maintainability, 1994
- [64] Zaretsky, E.V., Poplawski, J.V., Miller, C.R., „*Rolling Bearing Life Prediction - Past, Present and Future*”, NASA Technical Memorandum 2000
- [65] Srivastava, A.N., Mah, R.W., Meyer, C., „*Integrated Vehicle Health Management*”, NASA Aviation Safety Program, Technical Plan, 2009
- [66] Hunt, S.R., Hebden, I.G., „*Eurofighter 2000 An Integrated Approach to Structural Health and Usage Monitoring*”, RTO AVT Specialists Meeting 1998

- [67] Kühl, T., Pakszies, A., „*Condition Monitoring of Civil Jet Engines during Flight*”, LTH Triebwerkstechnologie, AT 58 100-01, 2011
- [68] Meeker, W.Q., Hamada, M., „*Statistical Tools for the Rapid Development & Evaluation of High-Reliability Products*”, IEEE Transactions on Reliability 1999, Vol. 44, pp.187-198
- [69] Lybeck, N., Marble, S., Morton, B., „*Validating Prognostic Algorithms: A Case Study Using Comprehensive Bearing Fault Data*”, IEEE Aerospace Conference 2007
- [70] Ljung, L., „*System Identification: Theory for the User*”, Prentice Hall, 1987
- [71] Isermann, R., „*Model-based fault-detection and diagnosis - status and applications*”, Annual Reviews in Control 2005, Vol. 29, pp. 71-85
- [72] De Jong, K., „*Learning with Genetic Algorithms: An Overview*”, Journal of Machine Learning 1988, Vol. 3, pp. 121-138
- [73] Hinchliffe, M.P., „*Dynamic Modelling Using Genetic Programming*”, Dissertation, University of Newcastle, 2001
- [74] Koza, J., „*Genetic Programming: On the Programming of Computers by means of Natural Selection*”, MIT Press, Cambridge, MA, 1992
- [75] Winkler, S., Affenzeller, M., Wagner, S., „*Genetic Programming Based Model Structure Identification using On-Line System Data*”, Proceedings of Conceptual Modeling and Simulation Conference 2005
- [76] Tao, Y., Li, M., Cao, J., „*Dynamic Population Variation Genetic Programming with Kalman Operator for Power System Load Modeling*”, Neural Information Processing: Theory and Algorithms, Springer Verlag 2010
- [77] Schaab, J., „*Trusted Health Assessment of Dynamic Systems Based on Hybrid Joint Estimation*”, VDI Verlag, 2011
- [78] van der Merwe, R., „*Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models*”, Dissertation, Oregon Health & Science University, 2004
- [79] Kalman, R.E., „*A New Approach to Linear Filtering and Prediction Problems*”, Journal of Fluids Engineering 1960, Vol. 82, pp. 35–45
- [80] Smith, G.L., McGee, L.A., „*Application of Statistical Filter Theory to the Optimal Estimation of Position and Velocity on Board a Circumlunar Vehicle*”, NASA TR R-135, 1962
- [81] Julier, S. J., „*The Scaled Unscented Transformation*”, Proceedings of the American Control Conference 2002, Vol. 6, pp. 4555-4559
- [82] Julier, S.J., Uhlmann, J.K., Durrant-Whyte, H.F., „*A New Approach for Filtering Nonlinear Systems*”, Proceedings of the American Control Conference 1995, Vol. 3, pp. 1628-1632
- [83] Doucet, A., Godsill, S., Andrieu, C., „*On sequential Monte Carlo sampling methods for Bayesian filtering*”, Journal of Statistics and Computing 2000, Vol. 10, pp. 197-208
- [84] Gordon, N.J., Salmond, D.J., Smith, A.F.M., „*Novel Approach to Nonlinear/Non-Gaussian Bayesian State Estimation*”, Journal of Radar and Signal Processing 1993, Vol. 140, pp. 107-113
- [85] Arulampalam, M.S., Maskell, S., Gordon, N., Clapp, T., „*A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking*”, IEEE Transaction on Signal Processing 2002, Vol. 50, pp. 174-188

- [86] Gove, J.H., Hollinger, D.Y., „*Application of a dual unscented Kalman filter for simultaneous state and parameter estimation in problems of surface-atmosphere exchange*”, Journal of Geophysical Research 2006, Vol. 111
- [87] Zhang, X., Pisu, P., „*An Unscented Kalman Filter Based Approach for the Health-Monitoring and Prognostics of a Polymer Electrolyte Membrane Fuel Cell*”, Annual Conference of the Prognostics and Health Management Society 2012
- [88] Mahdianfar, H., Pavlov, A., Aamo, O.M., „*Joint Unscented Kalman Filter for State and Parameter Estimation in Managed Pressure Drilling*”, European Control Conference 2013, pp. 1645-1650
- [89] Bar-Shalom, Y., Li, R. X., Kirubarajan, T., „*Estimation with Applications to Tracking and Navigation*”, John Wiley & Sons, 2001
- [90] Simpson, R., Revell, J., „*Towards a Taxonomy of Performance Metrics, Bounds and Tests for Tracking and SLAM Algorithms*”, Proceedings of the 4th SEAS DTC Technical Conference 2009
- [91] Mohamed, A.H., Schwarz, K.P., „*Adaptive Kalman Filtering for INS/GPS*”, Journal of Geodesy 1998, Vol. 73, pp. 193-203
- [92] Li, X.R., Jilkov, V.P., „*A Survey of Maneuvering Target Tracking-Part V: Multiple-Model Methods*”, IEEE Transactions on Aerospace and Electronic Systems 2003
- [93] Li, X.R., Zhao, Z., „*Measures of Performance for Evaluation of Estimators and Filters*”, Proceedings of Signal and Data Processing of Small Targets 2001, Vol. 4473
- [94] Zhang, Y., Jiang, J., „*Integrated Active Fault-Tolerant Control Using IMM Approach*”, IEEE Transactions on Aerospace and Electronic Systems 2001, Vol. 37, pp. 1221-1235
- [95] Drolet, L., Michaud, F., Jean Cote, J., „*Adaptable Sensor Fusion Using Multiple Kalman Filters*”, Proceedings of Intelligent Robots and Systems 2000, Vol.2, pp. 1434-1439
- [96] Shima, T., Oshman, Y., Shinar, J., „*Efficient Multiple Model Adaptive Estimation in Ballistic Missile Interception Scenarios*”, Journal of Guidance, Control and Dynamics 2002, Vol. 25, pp. 667-675
- [97] Orchard, M.E., „*A Particle Filtering-based Framework for On-line Fault Diagnosis and Failure Prognosis*”, Dissertation, Georgia Institute of Technology, 2006
- [98] Engel, S.J., Gilmartin, B.J., Bongort, K., Hess, A., „*Prognostics, The Real Issues Involved With Predicting Life Remaining*”, IEEE Proceedings of Aerospace Conference 2000, Vol. 6, pp. 457-469
- [99] Ribot, P., Pencol, Y., Combacau, M., „*Generic characterization of diagnosis and prognosis for complex heterogeneous systems*”, International Journal of Prognostics and Health Management 2013, Vol. 4
- [100] J. Daigle, M.J., Goebel, K., „*A Model-Based Prognostics Approach Applied to Pneumatic Valves*”, International Journal of Prognostics and Health Management 2011, Vol. 2
- [101] Usynin, A.V., „*A Generic Prognostic Framework for Remaining Useful Life Prediction of Complex Engineering Systems*”, Dissertation, University of Tennessee, 2007
- [102] Celaya, J.R., Saxena, A., Goebel, K., „*Uncertainty Representation and Interpretation in Model-based Prognostics Algorithms based on Kalman Filter Estimation*”, Annual Conference of the Prognostics and Health Management Society 2012

- [103] Johnson, S.B., Gormley, T., Kessler, S., Mott, C., Patterson-Hine, A., Reichard, K., Scandura, P., „*System Health Management: with Aerospace Applications*”, John Wiley & Sons, 2011
- [104] Hong, J., Shaked, S., Rosenbaum, R.K., Jolliet, O., „*Analytical uncertainty propagation in life cycle inventory and impact assessment: application to an automobile front panel*”, International Journal of Life Cycle Assessment 2010, Vol. 15, pp. 499-510
- [105] Wang, X., Cen, S. Li, C., „*Generalized Neumann Expansion and Its Application in Stochastic Finite Element Methods*”, Mathematical Problems in Engineering 2013
- [106] ISO/IEC Guide 98-3:2008, „*Uncertainty of measurement - Part 3: Guide to the expression of uncertainty in measurement*”, International Organization for Standardization, 2008
- [107] Kumar, M., Singla, P., Chakravorty, S., Junkins, J.L., „*A Multi-Resolution Approach for Steady State Uncertainty Determination in Nonlinear Dynamical Systems*”, Proceedings of the 38th Southeastern Symposium on System Theory 2006
- [108] Terejanu, G., Singla, P., Singh, T., Scott, P.D., „*Uncertainty Propagation for Nonlinear Dynamic Systems Using Gaussian Mixture Models*”, Journal of Guidance, Control and Dynamics 2008, Vol. 31, pp. 1623-1633
- [109] Sreenuch, T., Alghassi, A., Perinpanayagam, S., „*Probabilistic Monte-Carlo Method for Modelling and Prediction of Electronics Component Life*”, International Journal of Advanced Computer Science and Applications 2014, Vol. 5
- [110] Edwards, D., Orchard, M.E., Goebel, K., Vachtsevanos, G., „*Impact of Input Uncertainty on Failure Prognostic Algorithms: Extending the Remaining Useful Life of Nonlinear Systems*”, Annual Conference of the Prognostics and Health Management Society 2010
- [111] Candela_ , J.Q., Girard, A., Larsen, J., Rasmussen, C.E., „*Propagation of Uncertainty in Bayesian Kernels Models - Application to Multiple-Step Ahead Forecasting*”, International Conference on Acoustics, Speech and Signal Processing 2003, Vol. 2, pp. 701-704
- [112] Daigle, M., Saha, B., Goebel, K., „*A Comparison of Filter-based Approaches for Model-based Prognostics*”, IEEE Aerospace Conference 2012, pp. 1-10
- [113] Lall, P., Lowe, R., Goebel, K., „*Prognostics Using Kalman-Filter Models and Metrics for Risk Assessment in BGAs Under Shock and Vibration Loads*”, Proceedings of the 60th Electronic Components and Technology Conference 2010, pp. 889-901
- [114] Daigle, M., Saxena, A., Goebel, K., „*An Efficient Deterministic Approach to Model-based Prediction Uncertainty Estimation*”, Annual Conference of the Prognostics and Health Management Society 2012
- [115] Bayes, T., „*An Essay towards solving a Problem in the Doctrine of Chances*”, Philosophical Transactions of the Royal Society of London 1763, pp. 370-418
- [116] Archard, J.F., Hirst, W., „*The Wear of Metals under Unlubricated Conditions*”, Proceedings of the Royal Society of London 1956, pp. 397-410
- [117] Paris, P. C., Erdogan, F., „*A Critical Analysis of Crack Propagation Laws*”, Journal of Fluids Engineering 1963, Vol. 85, pp. 528-533
- [118] Saxena, A., Celaya, J., Balaban, E., Saha, B., Goebel, K., Saha, S., Schwabacher, M., „*Metrics for Evaluating Performance of Prognostic Techniques*”, International Conference on Prognostics and Health Management 2008

- [119] Saxena, A., Celaya, J., Saha, B., Goebel, K., Saha, S., „*On Applying the Prognostic Performance Metrics*”, Annual Conference of the Prognostics and Health Management Society 2009
- [120] Lu, C.J., Meeker, W.Q., „*Using Degradation Measures to Estimate a Time-to-Failure Distribution*”, Technometrics 1993, Vol. 35, pp. 161-174
- [121] Penrose, H., „*Electrical Motor Diagnostics*”, Success By Design, 2008
- [122] Choi, Y., Liu, C.R., „*Spall progression life model for rolling contact verified by finish hard machined surfaces*”, Wear 2007, Vol. 262, pp. 24-35
- [123] Li, B., Chow, M.Y., Tipsuwan, Y., Hung, J.C., „*Neural-Network-Based Motor Rolling Bearing Fault Diagnosis*”, IEEE Transactions on Industrial Electronics 2000, Vol. 47, pp. 1060-1069
- [124] Aherwar, A., Khalid, M.S., „*Vibration Analysis Techniques for Gearbox Diagnostics: A Review*”, International Journal of Advanced Engineering Technology 2012, Vol. 3
- [125] Nguyen, D.T., Xu, D.Y., „*Efficient technique for Scale-Space Imaging of Planar Objects*”, Electronics Letters 1987, Vol. 23, pp. 1326-1327
- [126] Rasmussen, C.E., Williams, C.K.I., „*Gaussian Processes for Machine Learning*”, MIT Press, 2006
- [127] Roberts, S., Osborne, M., Ebdon, M., Reece, S., Gibson, N., Aigrain, S., „*Gaussian Processes for Timeseries Modelling*”, Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences 2012, Vol. 371
- [128] Costa, E.O., Pozo, A.T.R., Vergilio, S.R., „*A Genetic Programming Approach for Software Reliability Modeling*”, IEEE Transactions on Reliability 2010, Vol. 59, pp. 222-230
- [129] Elandt-Johnson, R.C., Johnson N.L., „*Survival Models and Data Analysis*”, John Wiley & Sons, 1980
- [130] Blumenfeld, D., „*Operations Research Calculations Handbook*”, CRC Press 2010

Anhang A – Algorithmen

A.1 Implementierung der Genetischen Programmierung

Diese Implementierungsform ist in [74] näher erläutert.

$$\begin{aligned} \text{Initialgeneration (für } i = 1:N_{id}, j = 1:k_i): \\ f_{i,j} \sim p(f) \\ g_{i,j} = f_{i,j} \end{aligned} \quad (1)$$

$$\begin{aligned} \text{Initialgeneration (für } i = 1:N_{id}, j = 1:m_i): \\ c_{i,j} \sim p(c) \\ g_{i,j} = x_{i,j} \sim p_x \\ g_{i,j} = c_{i,j} \sim p_c \end{aligned} \quad (2)$$

$$\text{Trainings- und Validierungsphase (für } i = 1:N_{id}): \quad F(e_i) \rightarrow v_{i,1,\dots,J} \quad (3)$$

$$\begin{aligned} \text{Auswertung der individuellen Fitness (für } i = 1:N_{id}): \\ \varepsilon_i = \frac{\sum_{j=1}^J w_j \cdot v_j}{\sum_{j=1}^J w_j} \end{aligned} \quad (4)$$

$$\begin{aligned} \text{Auswahl der Individuen für Folgegeneration (für } i = 1:N_{id}): \\ e_i \sim \frac{\varepsilon_i}{\sum_{j=1}^J \varepsilon_j} \end{aligned} \quad (5)$$

$$\text{Auswahl eines genetischen Operators (für } i = 1:N_{id}): \quad g_i \sim p(g) \quad (6)$$

$$\text{Anwendung der genetischen Operatoren (für } i = 1:N_{id}): \quad \hat{e}_i = g_i(e_i) \quad (7)$$

$$\text{Erstellung der Folgegeneration (für } i = 1:N_{id}): \quad e_i = \hat{e}_i \quad (8)$$

für $n = 2:N_{gmax}$ Wiederholung der Schritte (3) – (8) bis die maximale Anzahl der Generationen oder eine geforderte Fitness erreicht wird

mit:

g	= Element aus Bibliothek, Inputs oder Konstanten
N_{id}	= Anzahl der Individuen pro Generation
k	= Anzahl der Knotenpunkte für einzelnes Individuum
m	= Anzahl der Endpunkte für einzelnes Individuum
$p(f)$	= Wahrscheinlichkeit für Auswahl einer Bibliotheksfunktion
$p(x)$	= Wahrscheinlichkeit für Auswahl eines bestimmten Inputs
$p(c)$	= Wahrscheinlichkeit für Auswahl einer Konstanten
p_x	= Wahrscheinlichkeit für Anbindung eines Inputs
p_c	= Wahrscheinlichkeit für Anbindung einer Konstanten
$F(e)$	= Systemmodell für ausgewähltes Individuum
v	= Erreichte Werte der einzelnen Bewertungskriterien
w	= Gewichtung der einzelnen Bewertungskriterien
J	= Anzahl der Bewertungskriterien
$p(g)$	= Wahrscheinlichkeit für Auswahl eines Operators
N_{gmax}	= Anzahl der Generationen

A.2 Unscented Kalman Filter als Zustandsschätzer

Diese Implementierungsform ist in [86] näher erläutert.

Filterinitialisierung: $\hat{x}_0 = E(x_0)$

$$P_{x0} = E\left[(x_0 - \hat{x}_0) \cdot (x_0 - \hat{x}_0)^T\right]$$

Gewichtung der
Sigma-Punkte:

$$w_0^{(m)} = \frac{\lambda}{n_x + \lambda} \quad i = 0$$

$$w_0^{(c)} = \frac{\lambda}{n_x + \lambda} + (1 - \alpha^2 + \beta) \quad i = 0$$

$$w_i^{(m)} = w_i^{(c)} = \frac{1}{2 \cdot (n_x + \lambda)} \quad i = 1, \dots, 2 \cdot n_x$$

wobei:

$$\lambda = \alpha^2 \cdot (n_x + \kappa) - n_x$$

mit:

n_x = Dimension des Zustandsvektors

α = Einfluss auf Verteilung der Sigma-Punkte (hier 10^{-3})

β = Form der Verteilung für Zustände (≈ 2 für Normalverteilung)

κ = Sekundärer Skalierungsparameter (hier 0)

Sigma-Punkte: $X_{k-1} = \left[\hat{x}_{k-1}, \hat{x}_{k-1} + \sqrt{(n_x + \lambda) \cdot P_{xk-1}}, \hat{x}_{k-1} - \sqrt{(n_x + \lambda) \cdot P_{xk-1}} \right]$

Prädiktionsschritt: $X_{k|k-1} = f(X_{k-1}, u_{k-1})$

$$\hat{x}_{k|k-1} = \sum_{i=0}^{2n_x} w_i^{(m)} X_{i,k|k-1}$$

$$P_{xk|k-1} = \sum_{i=0}^{2n_x} w_i^{(c)} (X_{i,k|k-1} - \hat{x}_{k|k-1}) \cdot (X_{i,k|k-1} - \hat{x}_{k|k-1})^T + Q_{xk}$$

$$X_{k|k-1} = \left[\hat{x}_{k|k-1}, \hat{x}_{k|k-1} + \sqrt{(n_x + \lambda) \cdot P_{xk|k-1}}, \hat{x}_{k|k-1} - \sqrt{(n_x + \lambda) \cdot P_{xk|k-1}} \right]$$

Messgleichungen: $Y_{k|k-1} = h(X_{k|k-1}, u_k)$

$$\hat{y}_{k|k-1} = \sum_{i=0}^{2n_x} w_i^{(m)} Y_{i,k|k-1}$$

Kovarianzen:

$$P_{yk} = \sum_{i=0}^{2n_x} w_i^{(c)} (Y_{i,k|k-1} - \hat{y}_{k|k-1}) \cdot (Y_{i,k|k-1} - \hat{y}_{k|k-1})^T + R_{yk}$$

$$P_{xk,yk} = \sum_{i=0}^{2n_x} w_i^{(c)} (X_{i,k|k-1} - \hat{x}_{k|k-1}) \cdot (Y_{i,k|k-1} - \hat{y}_{k|k-1})^T$$

Korrekturschritt:

$$K_k = P_{xk,yk} \cdot P_{yk}^{-1}$$

$$\hat{x}_k = \hat{x}_{k|k-1} + K_k \cdot (y_k - \hat{y}_{k|k-1})$$

$$P_{xk} = P_{xk|k-1} - K_k \cdot P_{yk} \cdot K_k^T$$

A.3 Unscented Kalman Filter als Parameterschätzer

Diese Implementierungsform ist in [86] näher erläutert.

Filterinitialisierung: $\hat{\xi}_0 = E(\xi_0)$

$$P_{x0} = E\left[(\xi_0 - \hat{\xi}_0) \cdot (\xi_0 - \hat{\xi}_0)^T\right]$$

Gewichtung der Sigma-Punkte:

$$w_0^{(m)} = \frac{\lambda}{n_\xi + \lambda} \quad i = 0$$

$$w_0^{(c)} = \frac{\lambda}{n_\xi + \lambda} + (1 - \alpha^2 + \beta) \quad i = 0$$

$$w_i^{(m)} = w_i^{(c)} = \frac{1}{2 \cdot (n_\xi + \lambda)} \quad i = 1, \dots, 2 \cdot n_\xi$$

wobei:

$$\lambda = \alpha^2 \cdot (n_\xi + \kappa) - n_\xi$$

mit:

ξ	= Parametervektor
n_ξ	= Dimension des Parametervektors
P_ξ	= Fehlerkovarianzmatrix der Modellparameter
α	= Einfluss auf Verteilung der Sigma-Punkte (hier 10^{-3})
β	= Form der Verteilung für Zustände (≈ 2 für Normalverteilung)
κ	= Sekundärer Skalierungsparameter (hier 0)

Sigma-Punkte:

$$\hat{\xi}_{k|k-1} = \xi_{k-1}$$

$$P_{\xi k|k-1} = P_{\xi k-1} + Q_{\xi k-1}$$

$$\Xi_{k|k-1} = \left[\hat{\xi}_{k|k-1}, \hat{\xi}_{k|k-1} + \sqrt{(n_\xi + \lambda) \cdot P_{\xi k|k-1}}, \hat{\xi}_{k|k-1} - \sqrt{(n_\xi + \lambda) \cdot P_{\xi k|k-1}} \right]$$

Messgleichungen:

$$Y_{k|k-1} = h(u_k, f(u_{k-1}, \Xi_{k|k-1}))$$

$$\hat{y}_{k|k-1} = \sum_{i=0}^{2n_x} w_i^{(m)} Y_{i,k|k-1}$$

Kovarianzen:

$$P_{yk} = \sum_{i=0}^{2n_x} w_i^{(c)} (Y_{i,k|k-1} - \hat{y}_{k|k-1}) \cdot (Y_{i,k|k-1} - \hat{y}_{k|k-1})^T + R_{yk}$$

$$P_{\xi k, yk} = \sum_{i=0}^{2n_x} w_i^{(c)} (\Xi_{i,k|k-1} - \hat{\xi}_{k|k-1}) \cdot (Y_{i,k|k-1} - \hat{y}_{k|k-1})^T$$

Korrekturschritt:

$$K_k = P_{\xi k, yk} \cdot P_{yk}^{-1}$$

$$\hat{\xi}_k = \hat{\xi}_{k|k-1} + K_k \cdot (y_k - \hat{y}_{k|k-1})$$

$$P_{\xi k} = P_{\xi k|k-1} - K_k \cdot P_{yk} \cdot K_k^T$$

mit:

Q_ξ = Kovarianzmatrix der Modellparameter für Modellunsicherheiten

A.4 Unscented Kalman Filter kombinierte Parameter- und Zustandsschätzung

Diese Implementierungsform wurde ausgehend von den Ergebnissen in [78] und [86] zur Parameter- und Zustandsschätzung hergeleitet.

Filterinitialisierung:

$$\hat{\chi}_0 = \begin{bmatrix} E(x_0) \\ E(\xi_0) \end{bmatrix}$$

$$P_{\chi 0} = E[(\chi_0 - \hat{\chi}_0) \cdot (\chi_0 - \hat{\chi}_0)^T]$$

Gewichtung der Sigma-Punkte:

$$w_0^{(m)} = \frac{\lambda}{n_\chi + \lambda} \quad i = 0$$

$$w_0^{(c)} = \frac{\lambda}{n_\chi + \lambda} + (1 - \alpha^2 + \beta) \quad i = 0$$

$$w_i^{(m)} = w_i^{(c)} = \frac{1}{2 \cdot (n_\chi + \lambda)} \quad i = 1, \dots, 2 \cdot n_\chi$$

wobei:

$$\lambda = \alpha^2 \cdot (n_\chi + \kappa) - n_\chi$$

mit:

χ

= Erweiterter Zustandsvektor

n_χ

= Dimension des erweiterten Zustandsvektors ($n_x + n_\xi$)

P_χ

= Fehlerkovarianzmatrix des erweiterten Zustandsvektors

α

= Einfluss auf Verteilung der Sigma-Punkte (hier 10^{-3})

β

= Form der Verteilung für Zustände (≈ 2 für Normalverteilung)

κ

= Sekundärer Skalierungsparameter (hier 0)

Sigma-Punkte:

$$X_{k-1} = \begin{bmatrix} \hat{\chi}_{k-1}, \hat{\chi}_{k-1} + \sqrt{(n_\chi + \lambda) \cdot P_{\chi^{k-1}}}, \hat{\chi}_{k-1} - \sqrt{(n_\chi + \lambda) \cdot P_{\chi^{k-1}}} \end{bmatrix} = \begin{bmatrix} X_{k-1} \\ \Xi_{k-1} \end{bmatrix}$$

Prädiktionsschritt:

$$X_{k|k-1} = \begin{bmatrix} f(X_{k-1}, u_{k-1}) \\ \Xi_{k-1} \end{bmatrix} = \begin{bmatrix} x_{k|k-1} \\ \xi_{k|k-1} \end{bmatrix}$$

$$\hat{\chi}_{k|k-1} = \sum_{i=0}^{2n_\chi} w_i^{(m)} X_{i,k|k-1}$$

$$P_{\chi^{k|k-1}} = \sum_{i=0}^{2n_\chi} w_i^{(c)} (X_{i,k|k-1} - \hat{\chi}_{k|k-1}) \cdot (X_{i,k|k-1} - \hat{\chi}_{k|k-1})^T + Q_{\chi^k}$$

$$X_{k|k-1} = \begin{bmatrix} \hat{\chi}_{k|k-1}, \hat{\chi}_{k|k-1} + \sqrt{(n_\chi + \lambda) \cdot P_{\chi^{k|k-1}}}, \hat{\chi}_{k|k-1} - \sqrt{(n_\chi + \lambda) \cdot P_{\chi^{k|k-1}}} \end{bmatrix}$$

Messgleichungen:

$$Y_{k|k-1} = h(u_k, X_{k|k-1})$$

$$\hat{y}_{k|k-1} = \sum_{i=0}^{2n_\chi} w_i^{(m)} Y_{i,k|k-1}$$

Kovarianzen:

$$P_{yk} = \sum_{i=0}^{2n_\chi} w_i^{(c)} (Y_{i,k|k-1} - \hat{y}_{k|k-1}) \cdot (Y_{i,k|k-1} - \hat{y}_{k|k-1})^T + R_{yk}$$

$$P_{\chi^k, yk} = \sum_{i=0}^{2n_\chi} w_i^{(c)} (X_{i,k|k-1} - \hat{\chi}_{k|k-1}) \cdot (Y_{i,k|k-1} - \hat{y}_{k|k-1})^T$$

Korrekturschritt:

$$K_k = P_{\chi^k, yk} \cdot P_{yk}^{-1}$$

$$\hat{\chi}_k = \hat{\chi}_{k|k-1} + K_k \cdot (y_k - \hat{y}_{k|k-1}) = \begin{bmatrix} \hat{x}_k \\ \hat{\xi}_k \\ \hat{\zeta}_k \end{bmatrix}$$

$$P_{\chi^k} = P_{\chi^k|k-1} - K_k \cdot P_{yk} \cdot K_k^T$$

mit:

Q_χ

= Kovarianzmatrix erweiterter Zustandsvektor für Modellunsicherheiten

Anhang B – Formeln und Parameter

B.1 Statistische Momente von Zufallszahlen

Die angegebenen Berechnungsvorschriften sind in [129] und [130] näher erläutert.

Summenbildung:	$E[x_1 + x_2] = E[x_1] + E[x_2]$	
	$\sigma^2(x_1 + x_2) = \sigma^2(x_1) + \sigma^2(x_2) + 2 \cdot \text{cov}(x_1, x_2)$	
Produktbildung:	$E[x_1 \cdot x_2] = E[x_1] \cdot E[x_2] + \text{cov}(x_1, x_2)$	
	$\sigma^2(x_1 \cdot x_2) = E[x_1]^2 \cdot \sigma^2(x_2) + E[x_2]^2 \cdot \sigma^2(x_1) + \dots$ $2 \cdot E[x_1] \cdot E[x_2] \cdot \text{cov}(x_1, x_2) + E[x_1] \cdot E[x_2] \cdot \text{cov}(x_1, x_2)$	Statistisch korreliert
	$\sigma^2(x_1 \cdot x_2) = E[x_1]^2 \cdot \sigma^2(x_2) + E[x_2]^2 \cdot \sigma^2(x_1) + \dots$ $\sigma^2(x_1) \cdot \sigma^2(x_2)$	Statistisch unkorreliert
Quotientenbildung:	$E\left[\frac{x_1}{x_2}\right] = \frac{E[x_1]}{E[x_2]}$	Taylorreihe 1ter Ordnung
	$E\left[\frac{x_1}{x_2}\right] = \frac{E[x_1]}{E[x_2]} \cdot \left(1 + \frac{\sigma^2(x_2)}{E[x_2]^2} - \frac{\text{cov}(x_1, x_2)}{E[x_1] \cdot E[x_2]}\right)$	Taylorreihe 2ter Ordnung
	$\sigma^2\left(\frac{x_1}{x_2}\right) = \frac{E[x_1]^2}{E[x_2]^2} \cdot \left(\frac{\sigma^2(x_1)}{E[x_1]^2} + \frac{\sigma^2(x_2)}{E[x_2]^2} - 2 \cdot \frac{\text{cov}(x_1, x_2)}{E[x_1] \cdot E[x_2]}\right)$	Taylorreihe 1ter Ordnung
sowie:	$\sigma^2(a + x_i) = \sigma^2(x_i)$	Addition Konstante
	$\sigma^2(a \cdot x_i) = a^2 \cdot \sigma^2(x_i)$	Multiplikation Konstante
mit:		
x_i	= Zufallszahl	
$E[\cdot]$	= Erwartungswert	
$\sigma^2(\cdot)$	= Varianz	
$\text{cov}(\cdot)$	= Kovarianz	

B.2 Verteilungsformen Maintenance Modell

Parameter	Verteilungstyp
Operationelle Verfügbarkeit (A_0)	Zweiparametrische Weibullverteilung (dynamischer Formparameter)
Service Capability Rate (SCR)	Zweiparametrische Weibullverteilung (dynamischer Formparameter)
Fehlerraten (λ_i)	Logarithmische Normalverteilung
Maintenance Index (MID)	Logarithmische Normalverteilung
Mittlere Reparaturzeiten (T_R)	Logarithmische Normalverteilung
Logistische Wartezeit (T_{LDT})	Logarithmische Normalverteilung
Fehlalarmraten ($\alpha_{BIT,COM}$)	Logarithmische Normalverteilung
Diagnosefehler (ε_D)	Logarithmische Normalverteilung
Prognosefehler (ε_P)	Logarithmische Normalverteilung

B.3 Varianzanteile Maintenance Modell

Modellgleichungen für die Kovarianzen der Sekundäreffekte:

$$\text{cov}(\lambda_{\text{CORROeff}}, \lambda_{\text{SFLTOf eff}}) = \sigma^2_{\text{CORROeff}} \cdot P_{\text{SFLT}}$$

$$\text{cov}(\lambda_{\text{CORRC}}, \lambda_{\text{SFLTC}}) = \sigma^2_{\text{CORRC}} \cdot P_{\text{SFLT}}$$

$$\text{cov}(\lambda_{\text{OCM}}, \lambda_{\text{SMNTOf eff}}) = \sigma^2_{\text{OCM}} \cdot P_{\text{SMNTeff}}$$

$$\text{cov}(\lambda_{\text{CBM}}, \lambda_{\text{SMNTC}}) = \sigma^2_{\text{CBM}} \cdot P_{\text{SMNT}}$$

wobei:

$$\lambda_{\text{SFLTOf eff}} = \lambda_{\text{CORROeff}} \cdot P_{\text{SFLT}}$$

$$\lambda_{\text{SFLTC}} = \lambda_{\text{CORRC}} \cdot P_{\text{SFLT}}$$

$$\sigma^2_{\text{OCM}} = \sigma^2_{\text{CORROeff}} \cdot (1 + P_{\text{SFLT}}^2) + 2 \cdot \text{cov}(\lambda_{\text{CORROeff}}, \lambda_{\text{SFLTOf eff}}) + \sigma^2_{\text{FAO}}$$

$$\sigma^2_{\text{CBM}} = \sigma^2_{\text{PREDCeff}} + \sigma^2_{\text{PREVCeff}} + \sigma^2_{\text{CORRC}} \cdot (1 + P_{\text{SFLT}}^2) + 2 \cdot \text{cov}(\lambda_{\text{CORRC}}, \lambda_{\text{SFLTC}}) + \sigma^2_{\text{FAC}}$$

$$\sigma^2_{\text{FAO}} = \sigma^2_{\text{CORROeff}} \cdot \left(\frac{\alpha_{\text{FA,BIT}}}{1 - \alpha_{\text{FA,BIT}}} \right)^2 + \sigma^2_{\text{BIT}} \cdot \lambda_{\text{CORROeff}}^2 + \sigma^2_{\text{CORROeff}} \cdot \sigma_{\text{BIT}}^2$$

$$\sigma^2_{\text{FAC}} = \sigma^2_{\text{CORRC}} \cdot \left(\frac{\alpha_{\text{FA,COM}}}{1 - \alpha_{\text{FA,COM}}} \right)^2 + \sigma^2_{\text{COM}} \cdot \lambda_{\text{CORRC}}^2 + \sigma^2_{\text{CORRC}} \cdot \sigma^2_{\text{COM}}$$

mit:

$$\kappa_{\text{BIT}} = 3 \text{ für } \kappa_x \text{ in (5.4) und } E[x] = \alpha_{\text{FA,BIT}} / (1 - \alpha_{\text{FA,BIT}}) \text{ in (5.5) für BIT Fehllalarme}$$

$$\kappa_{\text{COM}} = 3 \text{ für } \kappa_x \text{ in (5.4) und } E[x] = \alpha_{\text{FA,COM}} / (1 - \alpha_{\text{FA,COM}}) \text{ in (5.5) für COM Fehllalarme}$$

Modellgleichungen für die Varianzen der Diagnose & Prognose:

$$\sigma^2_{\text{PREVCeff}} = \sigma^2_{\text{PREVC}} \cdot (1 + \theta_D)^2 + \sigma^2_D \cdot \lambda_{\text{PREVC}}^2 + \sigma^2_{\text{PREVC}} \cdot \sigma^2_D$$

$$\sigma^2_{\text{PREDCeff}} = \sigma^2_P \cdot \lambda_{\text{PREDC}}^2$$

mit:

$$\kappa_D = 3 \text{ für } \kappa_x \text{ in (5.4) und } E[x] = \varepsilon_D \text{ in (5.5) für Diagnosefehler}$$

$$\kappa_P = 3 \text{ für } \kappa_x \text{ in (5.4) und } E[x] = \varepsilon_P \text{ in (5.5) für Prognosefehler}$$

Modellgleichungen für die Varianzen der resultierenden Wartungsmaßnahmen:

$$\sigma^2_{\text{geff}} = \sigma^2_{\text{PREDCeff}}$$

$$\sigma^2_{\text{ueff}} = \sigma^2_{\text{OCM}} \cdot (1 + P_{\text{SMNTeff}}^2) + 2 \cdot \text{cov}(\lambda_{\text{OCM}}, \lambda_{\text{SMNTOf eff}}) + \dots$$

$$\sigma^2_{\text{CBM}} \cdot (1 + P_{\text{SMNT}}^2) - \sigma^2_{\text{PREDCeff}} + 2 \cdot \text{cov}(\lambda_{\text{CBM}}, \lambda_{\text{SMNTC}})$$

B.4 Konfiguration Genetische Programmierung

Parameter	Parameterwert
Wahrscheinlichkeit für Auswahl des genetischen Operators für Crossover	0,85
Wahrscheinlichkeit für Auswahl des genetischen Operators für Mutation	0,1
Wahrscheinlichkeit für Auswahl des genetischen Operators für Direct Takeover	0,05
Wahrscheinlichkeit für Anbindung eines Inputs (p_x)	0,8
Wahrscheinlichkeit für Anbindung einer Konstanten (p_c)	0,2
Wahrscheinlichkeit für Mutation eines kompletten Teilgenes	0,9
Wahrscheinlichkeit für Mutation eines einzelnen Inputs	0,05
Wahrscheinlichkeit für Mutation einer einzelnen Konstanten	0,05

B.5 Parameter simulierte Degradierungsverläufe

Parameter	L1 & E1	L2 & E2	L3 & E3	Einheit
Erwartungswert Nutzungsdauer ($E[EoL]$)	1000	100	100	Std.
Startwert Degradierung (CI_0)	1	1	1	%
Formparameter Weibullverteilung (β)	5	25	1	-
Schrittweite Simulation (Δt)	1	1	1	Std.
Erwartungswert maximale Degradierung ($E[CI_{max}]$)	100	100	100	%
Grenzwert für Berücksichtigung äußere Last (p_n)	35	0	25	%
Minimalwert äußere Last (F_{min})	0	0	1	-
Maximalwert äußere Last (F_{max})	15	0	1,5	-

Anhang C – Validierung und Verifikation

C.1 Validierung Maintenance Modell

Für die Auswahl einer stabilen Konfiguration der Monte-Carlo Simulationen mit Simlox wurden die beiden Einstellungsmerkmale Simulationsdauer und Anzahl der Simulationsläufe betrachtet. Für Simlox lässt sich keine Auslastungsrate festlegen, sondern lediglich die von OPUS vorgegebene Ersatzteilmenge übernehmen. Deshalb wurden vor der Festlegung der Simlox Konfiguration zunächst zwei unterschiedliche Auslastungsraten als ein Unterscheidungsmerkmal zwischen OPUS und Simlox untersucht.

Für die Auslastungsrate lässt sich im Vergleich zum MMDL über den gesamten Wertebereich eine gute Übereinstimmung zwischen den Erwartungswerten von OPUS und den relativen 5% Perzentilen von Simlox beobachten:

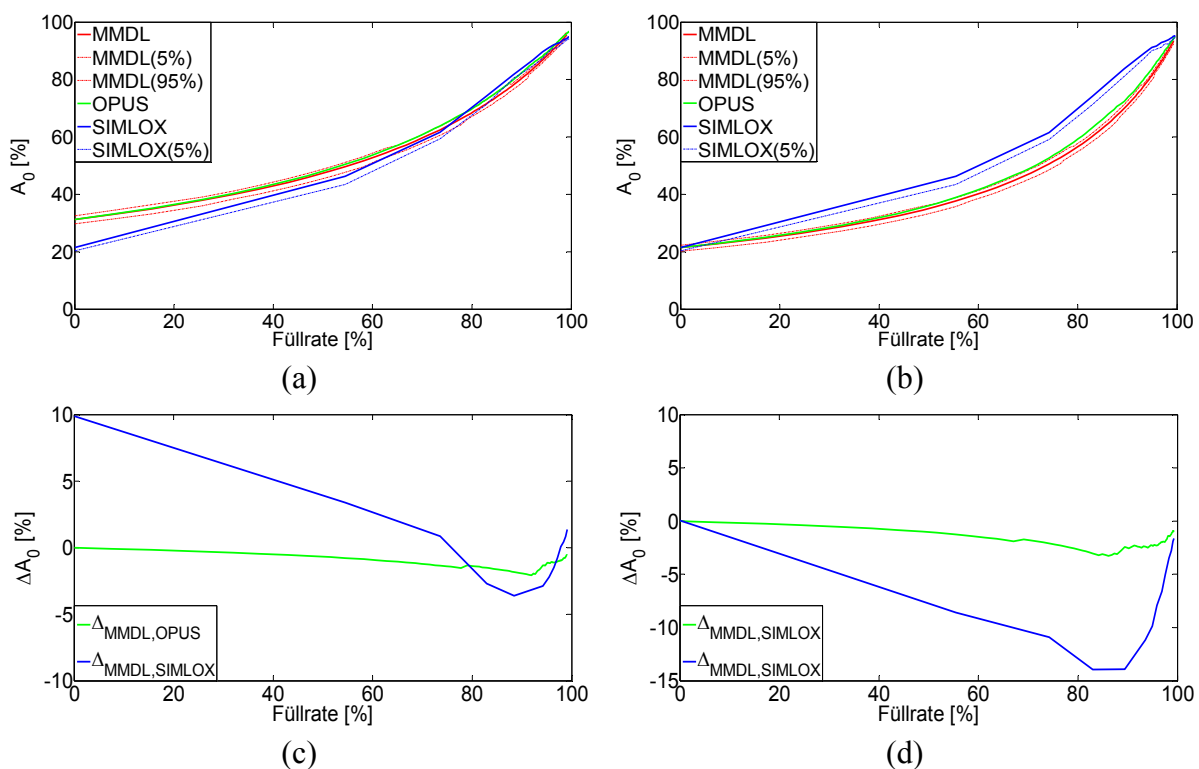


Abbildung 93: Einfluss der Auslastungsrate Luftsegment: (a) 60%, (b) 100%, (c) Residuen MMDL und OPUS / Simlox 60%, (d) Residuen MMDL und OPUS / Simlox 100%

Die nicht genutzte Betriebszeit für eine UR < 100% wird von OPUS und dem MMDL als zusätzliche operationelle Verfügbarkeit betrachtet, weswegen sich bei einer Erhöhung der UR von 60% auf 100% eine Reduzierung von A_0 beobachten lässt. Die Auslastungsrate wird nur bei OPUS und dem MMDL verwendet, während Simlox durch den konstanten Betrieb in der gewählten Konfiguration eine Auslastungsrate von 100% simuliert.

Somit wird in den Eckpunkten (0% und 100% FR³⁰) für UR = 60% auch eine signifikante Abweichung und für UR = 100% eine gute Übereinstimmung zwischen OPUS und Simlox erreicht.

Für die weiteren Validierungsschritte wurde für das Luftsegment eine Auslastungsrate von 60% und für das Bodensegment von 100% angenommen. Damit soll der abwechselnde Betrieb von zwei Luftsegmenten mit einem passiven Ersatzsystem simuliert werden.

Da die Bereitstellung der Ersatzteile für die Monte-Carlo Simulation ein Ausgabewert von OPUS ist, bildet Simlox in den folgenden Ergebnissen immer den Betrieb mit UR = 60% ab, woraus die Abweichung zwischen OPUS und Simlox resultiert.

Anhand des Vergleiches einer Nutzungsdauer von 1000 und 30000 Std. lässt sich ersehen, dass durch die zu geringe Simulationszeit von 1000 Std. die Generierung der Fehlerfälle in der Monte-Carlo Simulation nicht stabil ist und somit die Streuung der Verfügbarkeit zu große Unsicherheiten aufweist:

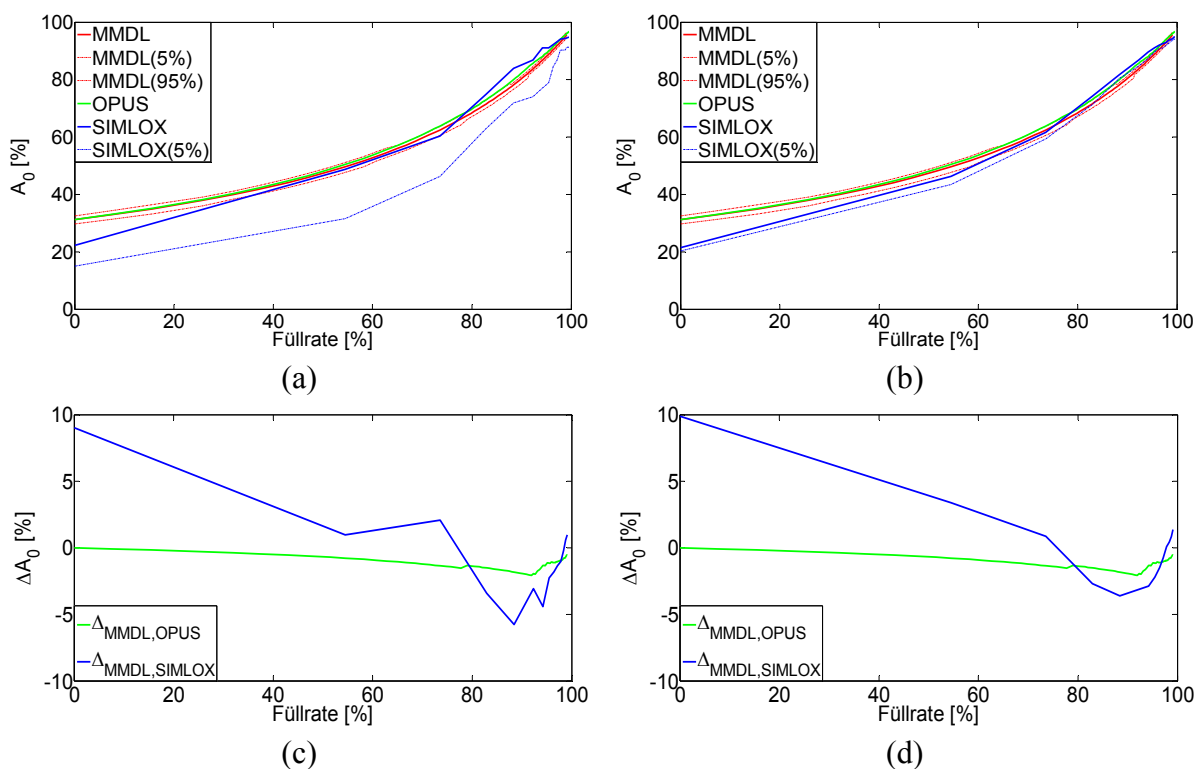


Abbildung 94: Einfluss der Nutzungsdauer Luftsegment: (a) 1000 Std., (b) 30000 Std., (c) Residuen MMDL und OPUS / Simlox 1000 Std., (d) Residuen MMDL und OPUS / Simlox 30000 Std.

Für eine Betriebsdauer von 30000 Std. ist ein stabiles Verhalten des Erwartungswertes und der 5% Perzentile zu beobachten, weswegen diese Größe für die weiterführenden Arbeiten genutzt wird.

³⁰ Für diese Eckpunkte ist kein Einfluss der Ersatzteilbevorratung vorhanden, da entweder jeder Fehler eine Wartezeit erfordert (0%) oder immer ein entsprechendes Ersatzteil vorhanden ist (100%).

Bei einer variierenden Anzahl der Simulationsläufe (Replikationen) lässt sich beobachten, dass die Vertrauensbereiche für 25 Testläufe ein vergleichbares Verhalten wie für 100 Testläufe aufweisen:

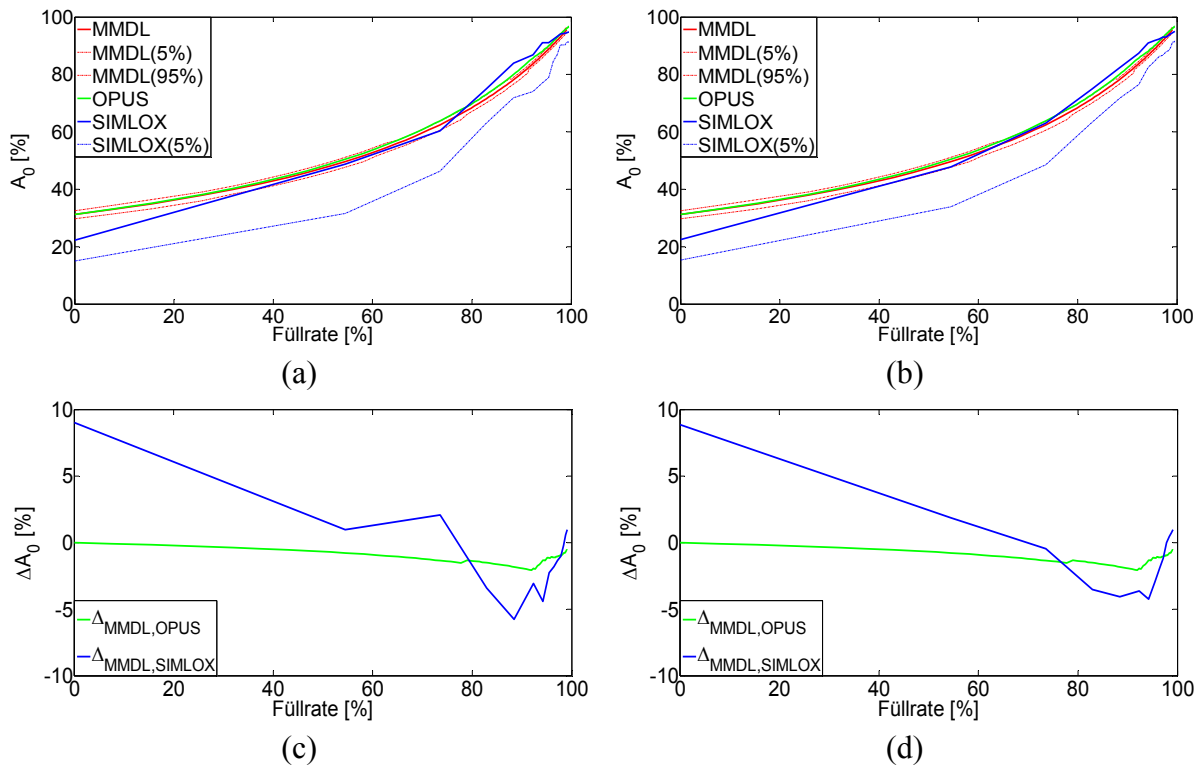


Abbildung 95: Einfluss der Anzahl Simulationen Luftsegment: (a) 25 Replikationen, (b) 100 Replikationen, (c) Residuen MMDL und OPUS / Simlox 25 Replikationen, (d) Residuen MMDL und OPUS / Simlox 100 Replikationen

Aufgrund von Speicherproblemen bei der verwendeten Hardwareumgebung konnten 100 Wiederholungen nur für eine Nutzungsdauer von 1000 Std. simuliert werden, wodurch die Streuung der Verfügbarkeit weiterhin relativ groß ist und nicht zur MMDL Validierung verwendet werden kann.

Ausgehend von den Ergebnissen der Voruntersuchungen sind die Parameter zur Konfiguration der Monte-Carlo Simulationen wie folgt bestimmt worden:

- 1) Nutzungsdauer 30000 Std.
- 2) 25 Replikationen

Diese Einstellungen wurden für alle anderen Validierungsschritte übernommen.

Um den Einfluss der Logistik zu untersuchen sind zwei Szenarien mit unterschiedlichen logistischen Vorlaufzeiten ($T_{L1} = 84$ Std., $T_{L2} = 252$ Std.) simuliert worden (s. [Abbildung 96](#)).

Betrachtet wurde ein fixes Versorgungsintervall mit $p_L = 1$ in (5.41). Neben der durch die erhöhten Wartezeiten reduzierten Verfügbarkeit lässt sich auch ein verhältnismäßig starker Einfluss auf den Gradienten als Funktion der FR beobachten. Dieser Effekt lässt sich damit begründen, dass beide Verläufe bei einer FR von 100% denselben Wert annehmen (kein Einfluss von logistischer Vorlauf-

zeit) aber durch die größeren Versorgungsintervalle einen unterschiedlichen Startpunkt haben und der letzte Abschnitt des zweiten Szenarios einer gestauchten Version des ersten Szenarios entspricht.

Auch für variierende Werte von T_W lässt sich bei gleichbleibender Einstellung aller anderen Modellgrößen eine hinreichende Übereinstimmung zwischen dem MMDL und den Verläufen der OPUS Erwartungswerte und relativen 5% Perzentile von Simlox beobachten:

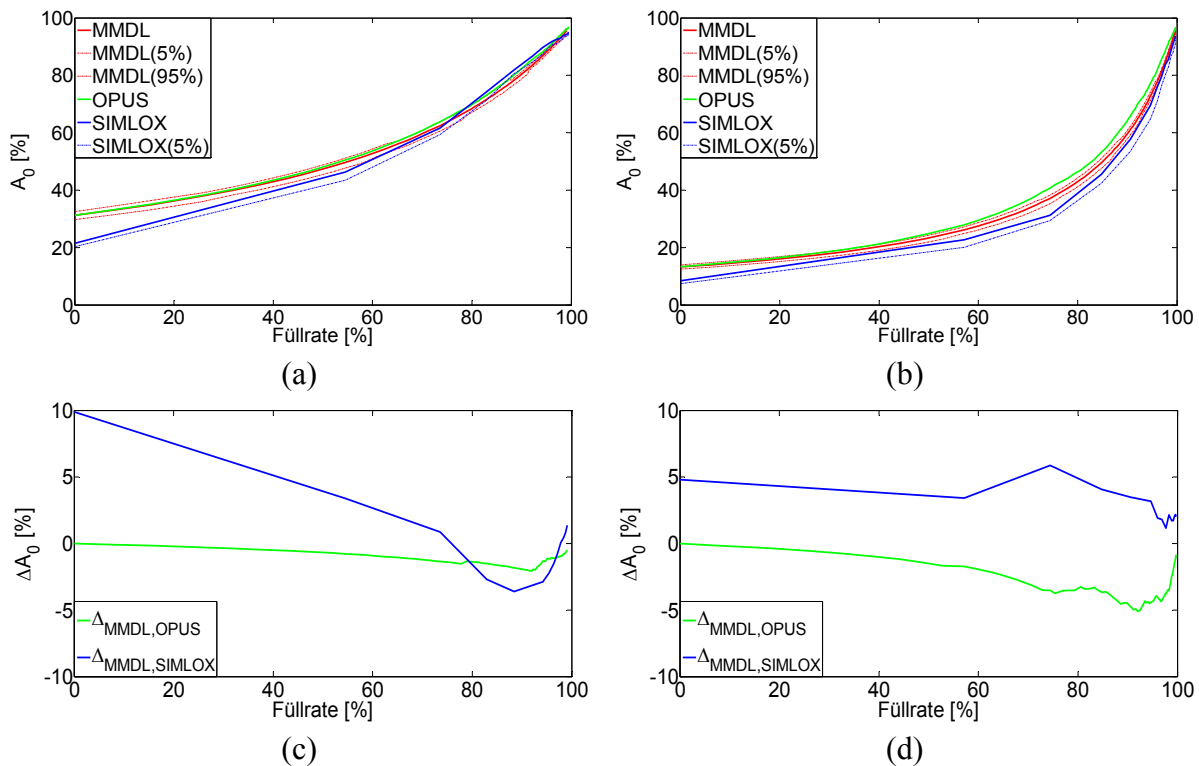


Abbildung 96: Einfluss der logistischen Vorlaufzeit Luftsegment: (a) 84 Std., (b) 252 Std., (c) Residuen MMDL und OPUS / Simlox 84 Std., (d) Residuen MMDL und OPUS / Simlox 252 Std.

Die Auswirkungen eines hybriden Wartungskonzeptes mit einem präventiven Wartungsanteil (abgebildet durch $P_{OCM} = 1$, $P_{PREVO} = 0,25$, $P_{CORRO} = 0,75$) auf die Verfügbarkeit sind in [Abbildung 97](#) dargestellt.

Anhand des idealisierten Verhaltens (alle als präventiv klassifizierten Fehler werden durch fixe Wartungsintervalle vermieden) lässt sich auch für ein hybrides Wartungskonzept die Validierung des MMDL auf Segmentebene bestätigen. Für ein nicht ideales Verhalten, was einem Fehlerfall zwischen zwei Wartungsintervallen nach (5.20) und (5.22) entspricht, reduziert sich die Verfügbarkeit durch die zusätzlichen Instandhaltungsmaßnahmen. Für diesen Anteil lässt sich zwar aufgrund der begrenzten Möglichkeiten der Systecon Suite (s. § 3.7.1) keine quantitative Validierung durchführen, jedoch entsprechen die Tendenz und auch der absolute Wert der resultierenden Verfügbarkeit dem erwarteten Verhalten.

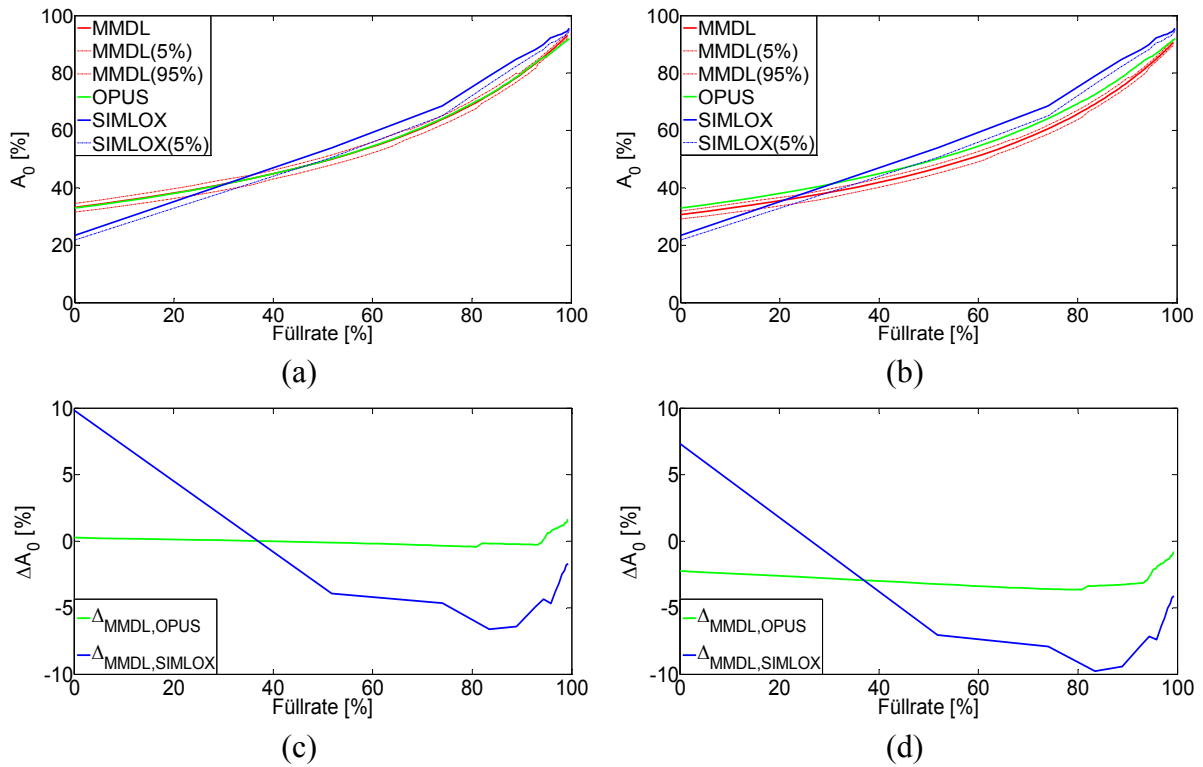


Abbildung 97: Hybrides Wartungskonzept Luftsegment: (a) Idealisiert, (b) Fehlerfall zwischen Inspektionen, (c) Residuen MMDL und OPUS / Simlox Idealisiert, (d) Residuen MMDL und OPUS / Simlox Fehlerfall zwischen Inspektionen

C.2 Verifikation Prognose lineare Modelle

In diesem Abschnitt werden zur Vervollständigung der Ergebnisse zusätzlich ausgewählte Anteile der Prognose für die linearen Modelle ausgewertet.

Die Prognose der Teilverläufe einer zufällig ausgewählten Trajektorie zeigt für alle Modelle eine zuverlässige Abbildung des mittleren Trends und der zugehörigen Vertrauensbereiche, so dass bereits für $t_0 = 0,25 \cdot \lambda$ die ermittelte PoF-Verteilung eine geeignete Maßnahme bietet, um eine prädictive Maßnahme zu planen:

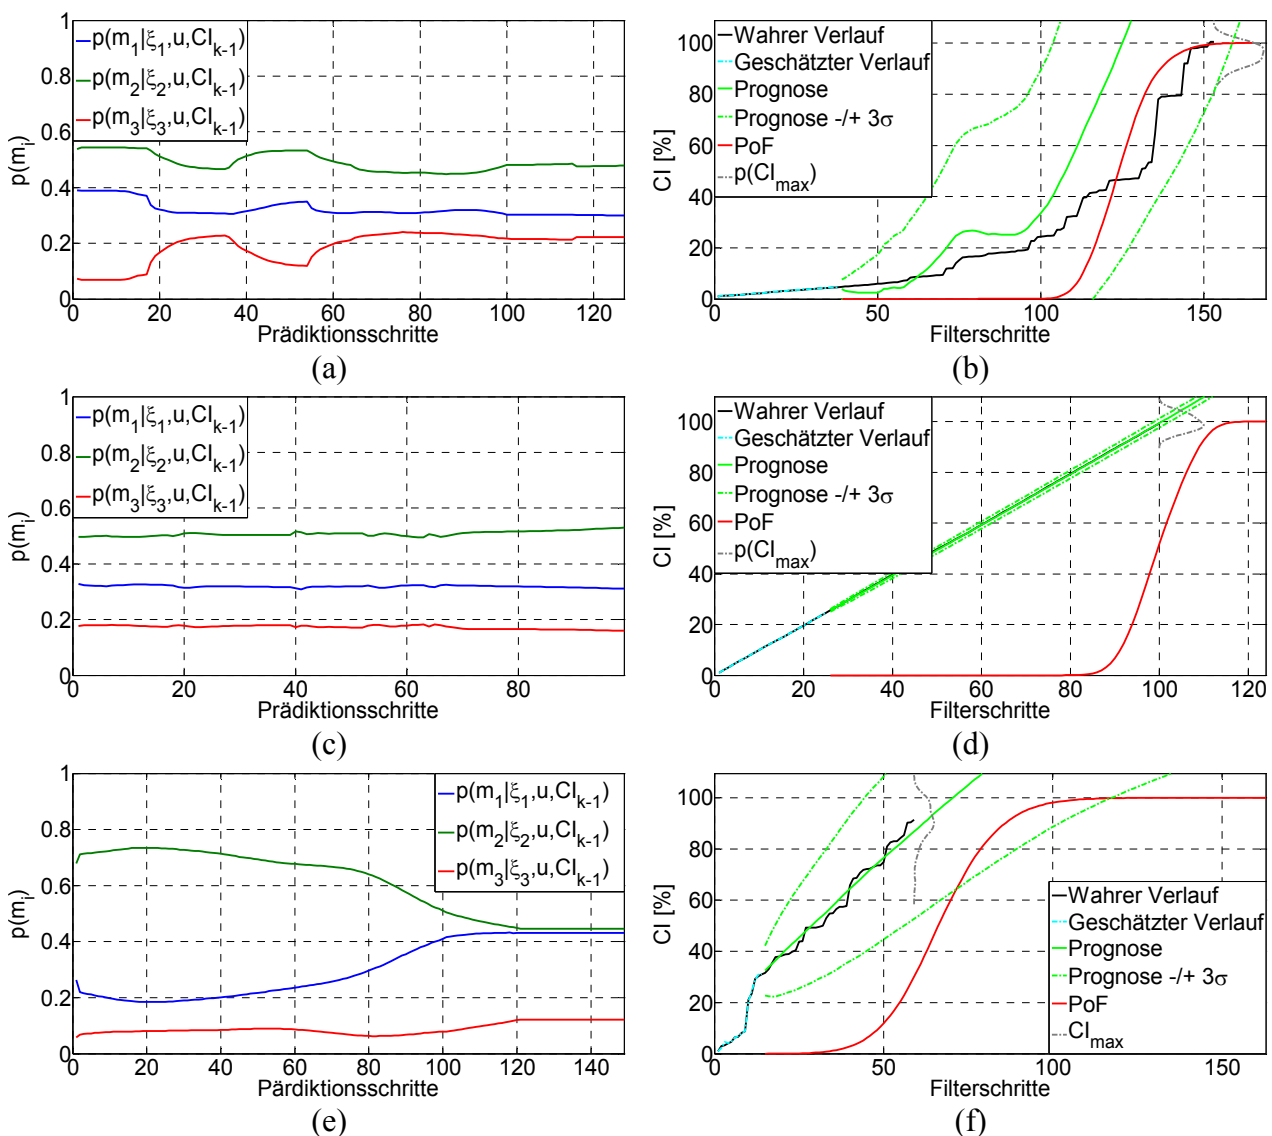


Abbildung 98: Prognosefunktion für Schadensmodelle L1-L3: (a), (c), (e) Modellgewichtungen in Prognosephase, (b), (d), (f) Prädiktion Einzeltrajektorie mit $t_0 = 0,25 \cdot \lambda$

Die über alle Verläufe gemittelte Verteilungsform der PoF (ausgedrückt durch die Vertrauensbereiche in **Fehler! Verweisquelle konnte nicht gefunden werden.**) ermöglicht im Durchschnitt ebenfalls eine sichere Vorgehensweise zur Vermeidung von Fehlern im Betrieb. Bei der Auswahl einer geeigneten Perzentile der PoF lässt sich der Fehlerfall für jede durchgeführte Prognose vermeiden.

Des Weiteren ist wie erwartet mit zunehmender Annäherung des Startpunktes der Prognose an den Ausfallzeitpunkt eine Abnahme der Unsicherheiten bei der Bestimmung der PoF zu beobachten.

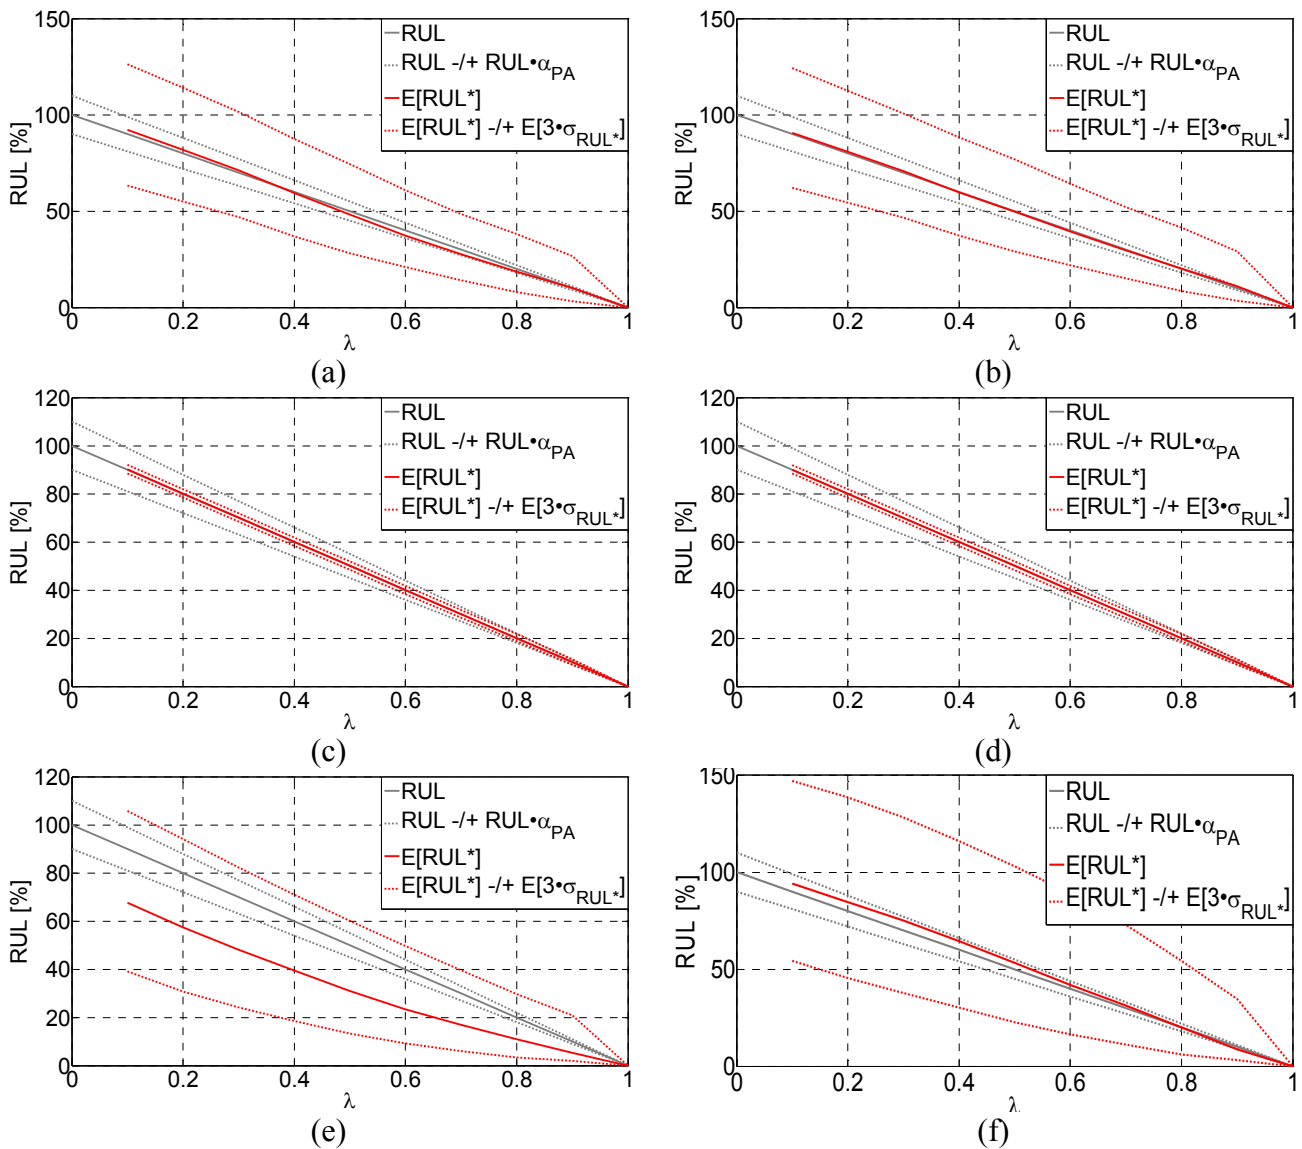


Abbildung 99: Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose über gesamten Datensatz für Schadensmodelle L1-L3: (a), (c), (e) Ohne Korrekturfaktor, (b), (d), (f) Mit Korrekturfaktor

C.3 Verifikation Prognose exponentielle Modelle

Analog zu den linearen Verläufen werden in diesem Abschnitt auch für die exponentiellen Modell-
daten einzelne Prognoseverläufe und die gemittelten Vertrauensbereiche ausgewertet. Für die ge-
zeigten Einzeltrajektorien lässt sich bereits früh eine zuverlässige Propagierung des Erwartungswertes
und der Vertrauensbereiche erzielen. Für Modell E3 ist zu Beginn ein Anstieg der prognostizierten
Varianz zu beobachten. Dieses Verhalten resultiert aus den unterschiedlichen Ausgabewerten
der Teilmodelle und der Bestimmung der fusionierten Kovarianz mit (7.49), da m_1 und m_2 zu die-
sem Zeitschritt eine entsprechend große Abweichung in den prognostizierten Zuständen aufweisen:

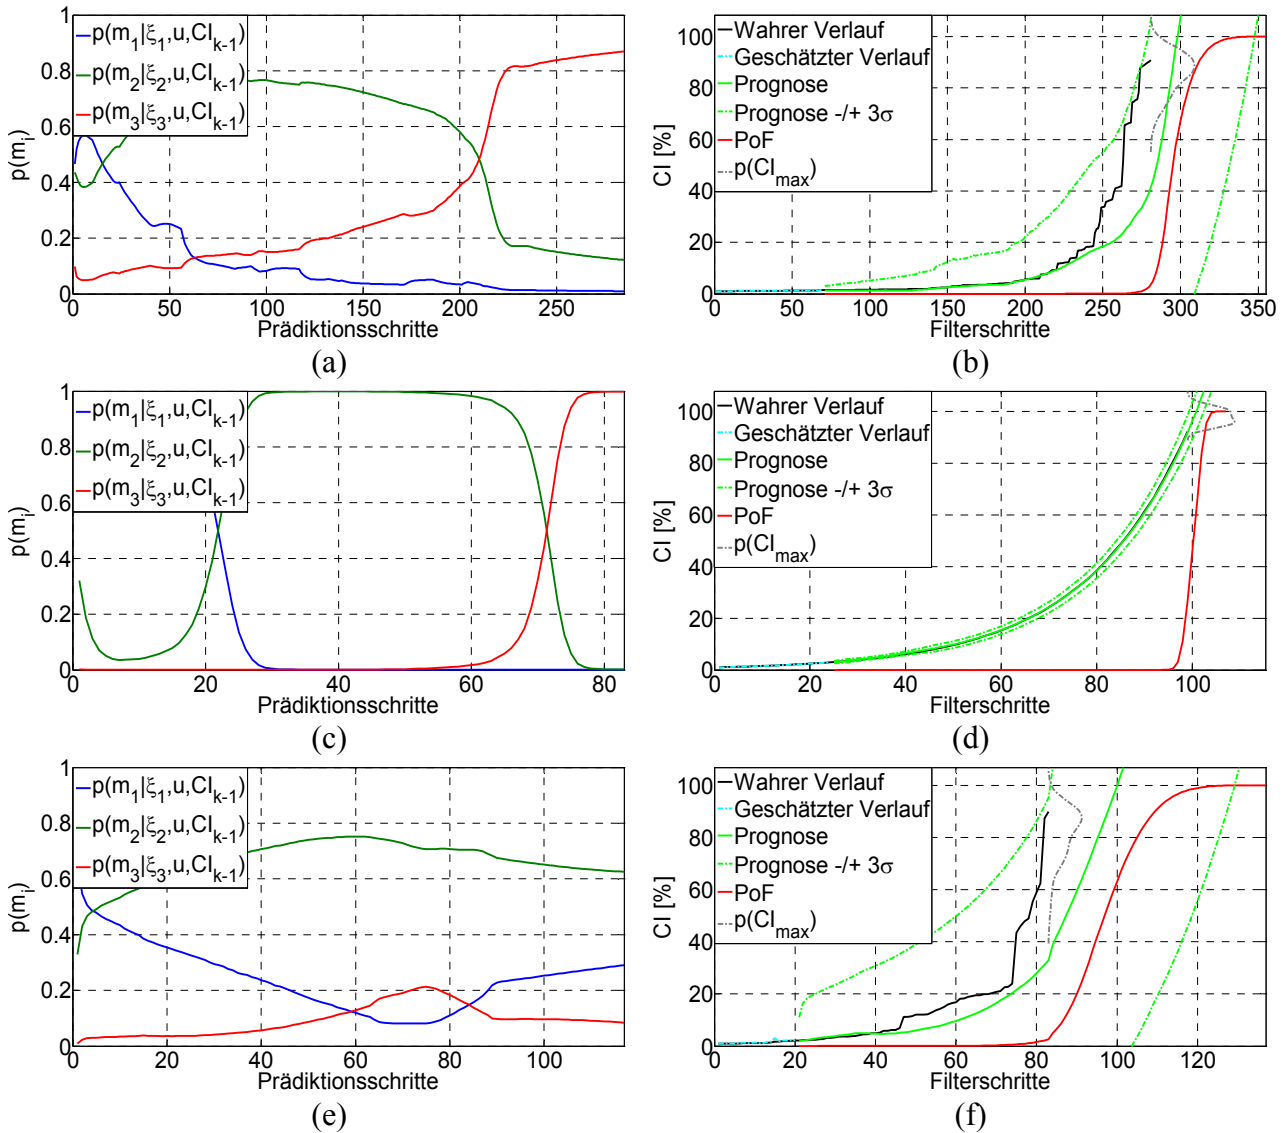


Abbildung 100: Prognosefunktion für Schadensmodelle E1-E3: (a), (c), (e) Modellgewichtungen in Prognosephase, (b), (d), (f) Prädiktion Einzeltrajektorie mit $t_0 = 0,25 \cdot \lambda$

Die Verläufe der Vertrauensbereiche konvergieren mit steigendem λ ebenfalls gegen ein Minimum und ermöglichen damit unabhängig vom Erwartungswert eine zunehmend präzisere Bestimmung des Ausfallzeitpunktes:

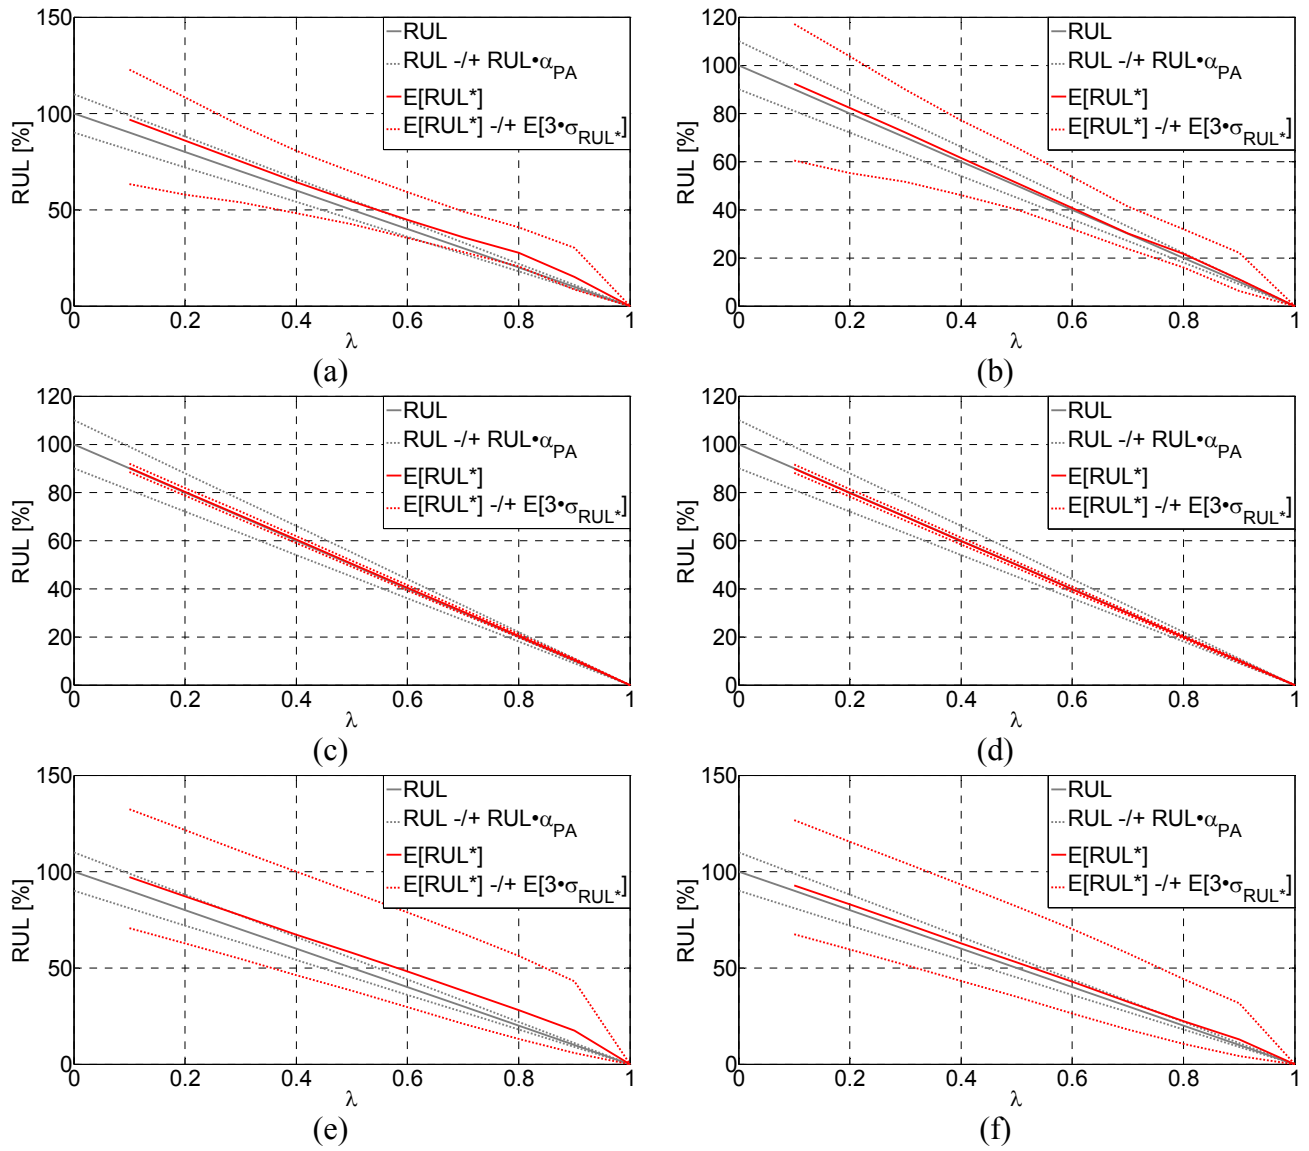


Abbildung 101: Erwartungswert und $\pm 3\sigma$ Vertrauensbereiche der Prognose über gesamten Datensatz für Schadensmodelle E1-E3: (a), (c), (e) Ohne Korrekturfaktor, (b), (d), (f) Mit Korrekturfaktor

Anhang D – Prüfstandskonfiguration**D.1 Lüfter AMETEK Rotron MAX50021 2900X7**

Parameter	Parameterwert	Einheit
Netzfrequenz	400	Hz
Spannung Phase-Phase	200	V
Spannung Phase-Neutral	115	V
Stromverbrauch Auslegungspunkt	3,2	A
Maximaler Stromverbrauch	5	A
Maximale Betriebstemperatur	130	°C
Leistungsaufnahme Auslegungspunkt	870	W
Drehzahl Auslegungspunkt	11280	rpm
Durchsatz Auslegungspunkt	235	l/s

D.2 Messdatenerfassung mit Beschleunigungssensoren KISTLER 8704B/4B50

Parameter	Parameterwert	Einheit
Messbereich	± 50	g
Maximalwert	± 100	g
Frequenzantwort im Bereich 0,5 - 10000 Hz	± 5	%
Resonanzfrequenz	54	kHz
Rauschpegel im Bereich 1 - 10000 Hz	≤ 35	μV_{rms}
Empfindlichkeit mit ± 5 Genauigkeit	100	mV/g
Ansprechschwelle	0,004	grms

BERUFLICHER WERDEGANG DES VERFASSERS

AUSBILDUNG

- Feb. 10 – Feb. 15** **Technische Universität Darmstadt, Deutschland**
Doktorand am Institut für Flugsysteme und Regelungstechnik
- Okt. 00 - Okt. 08** **Technische Universität Berlin, Deutschland**
Dipl.-Ing. für Luft- und Raumfahrttechnik
- Juni 91 - April 99** **Fichtenberg-Gymnasium (Berlin), Deutschland**
Allgemeine Hochschulreife

BERUFSERFAHRUNG

- Nov. 14 – heute** **Rolls-Royce Deutschland Ltd. & Co KG (Dahlewitz), Deutschland**
Systemingenieur im Bereich Fuel, Oil and Heat Management Systems
- März 09 – Sept. 14** **Airbus Group (Manching), Deutschland**
Systemingenieur bei Airbus Defence & Space im Bereich Supply and Propulsion Systems
- Sept. 08 - Feb. 09** **FTI Engineering Group (Dahlewitz), Deutschland**
Systemingenieur bei Rolls-Royce Deutschland im Bereich Controls
- März 07 - Feb. 08** **Rolls-Royce Deutschland Ltd. & Co KG (Dahlewitz), Deutschland**
Praktikant / Werkstudent im Bereich Controls
- Aug. 05 - Okt. 05** **ADMOS Gleitlager (Berlin), Deutschland**
Praktikum in den Bereichen Entwicklung / Konstruktion und Fertigung / Montage
- Mai 05 - April 07** **Cambridge International School (Berlin), Deutschland**
Mitarbeiter des Lehrkörpers im Fachbereich Mathematik und Physik

PUBLIKATIONEN

Virtual Framework for Validation and Verification of System Design Requirements to enable Condition Based Maintenance, European Conference of the Prognostics and Health Management Society 2012

Fault Detection based on MCSA for a 400Hz Asynchronous Motor for Airborne Applications, International Journal of Prognostics and Health Management 2013

Development of Diagnostics & Prognostics for Condition-Based Decision Support, European Conference of the Prognostics and Health Management Society 2014